



Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra kybernetiky

DIPLOMOVÁ PRÁCE

Modelování cévního řečiště jater s využitím kombinace snímků z
trojrozměrných lékařských zobrazovacích metod

PLZEŇ, 2019

Bc. Ondřej DUSPIVA

Prohlášení

Předkládám tímto k posouzení a obhajobě diplomovou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni. Prohlašuji, že jsem diplomovou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne 23. 8. 2019

.....
Bc. Ondřej DUSPIVA

Poděkování

Na tomto místě bych rád poděkoval Ing. Miroslavu Jiříkovi, Ph.D. za přínosné rady a laskavé vedení diplomové práce. Jemu i celé katedře bych také rád poděkoval za předané znalosti během celé doby mého studia.

ABSTRAKT

Tato práce se zabývá segmentací cévního řečiště v játrech z trojrozměrných obrazových dat. Mapuje metody počítačového vidění vhodné pro segmentaci a registraci cévního řečiště jater, včetně metod pro předzpracování obrazových dat. V práci jsou porovnány registrační metody využívající rigid body, non-rigid body a afinní transformace. Dále jsou popsány segmentační metody detekce hran, prahování, narůstání oblastí a metody založené na zkoumání okolí obrazového bodu.

Součástí práce je vlastní návrh metody pro registraci CT snímků a následnou segmentaci cévního řečiště v játrech.

Klíčová slova: registrace obrazových dat, segmentace cévního řečiště, rigid-body transformace, afinní transformace, non-rigid body transformace, B-Spline, region grow, narůstání oblastí, Frangiho filtr, ITK, LISA

ABSTRACT

This thesis focuses on the liver vascular system segmentation using volumetric image data. It charts methods of computer vision applicable for registration and vessels segmentation, including methods for images preprocessing. In the thesis, rigid body, non-rigid body and affine registration methods are compared. Further, segmentation methods for edge detection, thresholding, region grow and the picture points surrounding area are described.

This thesis includes own method for CT images registration and liver vascular system segmentation.

Key words: images registration, liver vascular system segmentation, rigid-body transformation, affine transformation, non-rigid body transformation, B-Spline, region grow, Frangi's filter, ITK, LISA

OBSAH

1. ÚVOD	1
2. ZOBRAZOVACÍ METODY	2
2.1 Zobrazovací metody v medicíně	2
2.2 Rentgen	2
2.2.1 Princip vzniku rentgenového záření	2
2.3 Výpočetní tomografie CT	3
2.3.1 Historie CT	3
2.3.2 Princip CT	4
2.3.3 Hounsfieldovy jednotky	7
2.4 Magnetická rezonance	8
2.4.1 Historie	9
2.5 Rozdíl mezi CT a MRT	9
3. FORMÁT DICOM	10
4. ITK A SIMPLE ITK	11
5. PŘÍPRAVA OBRAZOVÝCH DAT	12
5.1 Histogram equalization	12
5.2 CLAHE	13
5.3 Vyhlazování	13
5.3.1 Konvoluce	13
5.3.2 Gaussův filtr	14
5.3.3 Metoda rotující masky	15
5.3.4 Nelineární filtry	15
5.3.4.1 Mediánový filtr	15
5.3.4.2 Konzervativní vyhlazení	16
5.3.4.3 Prahování vlnkových koeficientů	16
5.3.4.4 Bilaterální filtr	16
5.3.5 Ukázka použití některých filtrů	17
6. SEGMENTACE	19
6.1 Prahování	19
6.1.1 Non-maximal suppression	20
6.1.2 Adaptivní prahování	21
6.1.3 Otsu	21

6.1.3.1	Procentní prahování	22
6.1.4	Další určení prahu	23
6.1.5	Výsledky jednotlivých metod	23
6.2	Detekce hran	24
6.2.1	Využití znalosti polohy hranic	24
6.2.2	Postupné dělení spojnic	24
6.2.3	Cannyho hranový detektor	24
6.2.4	Derivace a konvoluční masky	25
6.2.5	Aktivní kontury	26
6.2.6	Watershed segmentation	27
6.2.7	Houghova transformace	27
6.3	Narůstání oblastí - Region growing	28
6.4	Náhodné Markovské řetězce	28
6.5	Metody založené na zkoumání tvaru	29
6.5.1	Metoda založená na vlastních číslech Hessianovy matice - Frangiho filtr	29
6.5.2	Gaborovy filtry a K-means	31
6.6	Metoda Graph-Cut	33
7.	REGISTRACE OBRAZOVÝCH DAT	34
7.1	Rigid / Non-Rigid body registrace	35
7.1.1	Rigid body registrace	35
7.1.2	Non-Rigid body	35
7.1.3	Afinní transformace	36
7.1.4	Výhody a nevýhody jednotlivých přístupů a jejich souvislost se snímáním pacienta	36
7.2	Metody registrace obrazových dat	37
7.2.1	Bodová registrace	38
7.2.2	Registrace ploch	39
7.2.3	Registrace na základě podobnosti voxelů	39
7.2.3.1	Křížová korelace	39
7.2.3.2	Minimalizace variace poměrů intenzit	40
7.2.4	Registrace na základě informace	40
7.2.4.1	Entropie	41
7.2.4.2	Minimalizace celkové informace	41
7.2.4.3	Společná informace	42
7.2.5	B-Spline registrace	42
7.2.6	Non-image based registration	43
7.3	Optimalizátor	44
7.4	Interpolace	44
7.4.1	Metoda nejbližšího souseda	44
7.4.2	Bilineární interpolace	45
7.4.3	Bikubická interpolace	45
7.4.4	Spline interpolace	46

8. NÁVRH METODY PRO NALEZENÍ CEVNÍHO STROMU V CT SNÍMCÍCH	47
8.1 Registrace	47
8.2 Segmentace jater v jednotlivých sériích	50
8.3 Segmentace cévního stromu	51
8.3.1 Nalezení významných regionů	52
8.3.2 Segmentace pomocí prahování	53
8.3.3 Segmentace pomocí metody narůstání oblastí	53
8.3.4 Segmentace založená na analýze vlastních čísel Hessiany matice	53
9. ZÁVĚR	60

1. ÚVOD

Počítačové vidění je rychle se rozvíjející oblastí kybernetiky, která pomáhá v různých aplikacích. Hlavním cílem této oblasti je rozpoznávání obrazu, respektive získávání informací ze zachycených obrazů. Ty je pak možné použít například v oblasti automatizace průmyslu pro autonomní průmyslové roboty, detekci jevů například v bezpečnostním kamerovém systému, interakci člověka s počítačem nebo k realizaci autonomního řízení automobilů. Počítačové vidění nachází často uplatnění i v oblasti medicíny, kde je možné automaticky pomocí software ze získávaných medicínských dat a snímků provádět například automatickou diagnózu.

Díky velkému množství zobrazovacích metod využívaných v oblasti medicíny a díky moderním technikám počítačového vidění je možné usnadnit lékařům diagnózu, a to často s využitím kombinace několika zobrazovacích metod.

2. ZOBRAZOVACÍ METODY

2.1 Zobrazovací metody v medicíně

Zobrazovací metody jsou definovány ve Velkém lékařském slovníku následovně: lékařské vyšetřovací metody umožňující zobrazení orgánů a jejich částí v živém organismu bez narušení jejich životnosti. Kromě vlastního zobrazení struktury umožňují mnohé moderní metody i posouzení funkčního stavu. Z. m. využívají různých fyzikálních principů a k jejich rozvoji přispěl mj. i rozvoj počítačové techniky. K hlavním metodám patří rentgenové vyšetření v mnoha modifikacích vč. CT, ultrazvukové vyšetření ultrasonografie, magnetická rezonance MRI, izotopová vyšetření, PET aj. Zocor – simvastin, hypolipidemikum ze skupiny statinů) [1]

V dalších odstavcích jsou jednotlivé zobrazovací metody popsány podrobněji [2-4]

2.2 Rentgen

Rentgenové záření¹ - elektromagnetické záření o velmi krátké vlnové délce 10nm - 0,001nm. Pokud je vlnová délka rentgenového záření velmi malá, hovoříme o tvrdém rentgenovém záření, které má vyšší energii. Nižší energii pak má zcela logicky záření nazývané jako měkké, které má větší vlnovou délku.

2.2.1 Princip vzniku rentgenového záření

Při dopadu katodového záření - proudu elektronů, které jsou urychleny elektrickým polem na kovovou anodu dochází ke vzniku záření, které proniká i neprůhlednými předměty. Jako důsledek zpomalování pohybu elektronů dopadajících velkou rychlostí na anodu, dochází ke vzniku tzv. brzdného záření. Spektrum brzdného záření je spojité důsledkem spojitých změn frekvence. Dalším druhem záření, které vzniká, je tzv. charakteristické záření, které ji vzniká působením dopadajících elektronů. V tomto případě pozorujeme čárové spektrum. Obě tato záření dohromady tvoří pouze asi 1% z přeměnné kinetické energie urychlených elektronů. Zbytek (cca 99%) se přeměňuje na teplo.

Princip zobrazování pomocí tohoto záření je potom fakt, že rozdílné látky a tkáně pohlcují jiné množství rentgenového záření. Na snímači je pak měřena

¹ Rentgenové záření objevil v roce 1895 německý fyzik W. C. Röntgen během studia výbojů v plynech

intenzita dopadajícího zeslabeného rentgenového paprsku. Rentgenové záření se používá v naprosté většině přístrojů CT, jejichž funkce a princip je popsán v následující části.

2.3 Výpočetní tomografie CT

Výpočetní tomografie je metodou využívající matematické rekonstrukce obrazu získaného sérií rentgenových snímků. Pomocí této metody je možné regresivním způsobem zobrazovat měkké tkáně jako jsou například ledviny, svalstvo, mozek nebo játra. Touto metodou je možné zjistit patologické jevy, které se liší svou denzitou od okolní tkáně nebo okolí obecně.

2.3.1 Historie CT

Historie výpočetní tomografie sahá do roku 1963, kdy Allan Cormack (americký fyzik) vypracoval teorii o rekonstrukci tomografického řezu z několika sumačních snímků. V této teorii využil Allan Cormack gama záření. První skutečně použitelný tomograf byl však sestaven o necelých deset let později a to v roce 1972. Sestavil jej Godfrey Newbold Hounsfield.²



Fig. 2.1: EMI mark I sestavený Godfrey Newbold Hounsfield v roce 1972

Zdroj: <https://www.howitworksdaily.com/medical-history-the-nhs-through-the-decades/>

CT přístroje je možné rozdělit do několika generací:

1. generace - tato generace využívá tzv. Housfieldův systém, který byl použit i u přístroje EMI Mark I, snímkovací systém se v této generaci posouvá lineárně přes celou délku zkoumaného subjektu v dané rovině. Otočení je o zhruba $10^\circ - 15^\circ$. Zpracování snímků a vytvoření rekonstrukce trvalo cca 300 s.

² Allan Cormack a Godfrey Newbold Hounsfield obdrželi za své objevy v roce 1979 Nobelovu cenu.

2. generace - využívá stejný druh pohybu jako první generace, zmenšil se ovšem úhel mezi jednotlivými snímky na cca 3° - 10° a zvětšil se počet detektorů (až 60). Snížila se také doba rekonstrukce o více než 10 s a to na cca 20 s.
3. generace - tato generace je nejvíce využívanou variantou v současnosti. Rentgenka snímkuje objekt širokým snopcem záření za stálé rotace o 360° . Použito je několik stovek detektorů (řádově 400-600) na protilehlé matici vůči zářiči. Snímkování se provádí po méně než 1° a probíhá kontinuálně po celou dobu otočky³.
4. generace - používá rotující rentgenku, která opisuje celou kružnici záznam pak zajišťuje více než tisícovka stacionárních detektorů po obvodu. Problémem této generace je expozice okrajových detektorů, které jsou zasazeny rozptýleným a odraženým zářením.
5. generace - tzv. nutační systém se skládá z matice stacionárních detektorů a rotující rentgenky. Detektory se na základě pozice rentgenky vycylují z kolmice tak aby na ně paprsky dopadly kolmo. Tento systém umožňuje například rekonstrukci řezů v jiné než axiální rovině⁴.
6. generace - tato generace jako zdroj záření používá elektronové dělo. Anoda je vlastně výsečí kolem části obvodu zkoumaného objektu a má několik ohnisek. Zařízení je buzeno současně na několika ohniscích a detektory jsou umístěny do dvou prstenců okolo zkoumaného objektu. U této generace nedochází k žádnému pohybu. Zařízení je výše popsaným principem schopno snímkovat několik vrstev současně a to za extrémně krátkou dobu expozice, která se pohybuje okolo 50 ms.

2.3.2 Princip CT

Principem výpočetní tomografie, jak již bylo zmíněno výše je skládání celkového obrazu z mnoha jednotlivých snímků. Na následujícím obrázku je vidět, že je nutné snímkovat zkoumaný objekt z mnoha úhlů. Pokud by snímkování probíhalo, jen například ze 4 nebo 6 úhlů, výsledný obraz by byl zatížen velkou chybou.

U nejčastějšího typu CT přístrojů rotuje rentgenka v gántře kolem pacienta a v pulzech trvajících 1-4ms vysílá vějířovitý rentgenový paprsek. Ten prochází snímkováným objektem, kde je částečně absorbován. Po obvodu gántry jsou scintilační detektory, které zaznamenávají dopadající záření respektive míru jeho zeslabení. Tato informace je uložena do počítače a následně vyhodnocena.

³ Pokračováníma 3. generace je potom tzv. spirální (helikální) CT. To umožňuje postupný a plynulý posun stolu se zkoumaným objektem. Tato metoda byla poprvé použita v přístroji společnosti Bio-Imaging Research v roce 1986.

⁴ V současné době (cca od roku 1999) vznikly i tzv. multi-slice CT. Tyto přístroje jsou vybaveny několika systémy detektorů uspořádaných do kruhu a umožňují tím pádem získat více řezů v jednom okamžiku. Tímto způsobem ještě více urychlují vyšetření na druhou stranu stoupá jejich cena a náročnost údržby.

Obraz je potom informací o tom, jak jednotlivé voxely pohlcují záření⁵. Z pohledu medicíny je výsledkem výpočetní tomografie obraz pacienta v příčné (axiální) vrstvě, kdežto u rentgenových snímků vzniká obraz v frontální či sagitální vrstvě (v závislosti na poloze pacienta).

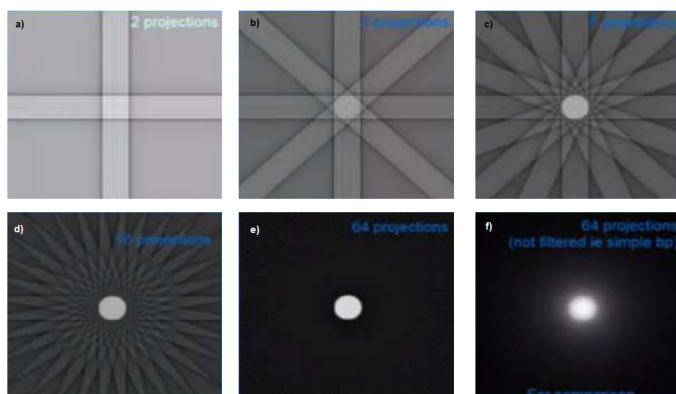


Fig. 2.2: Vliv počtu projekcí na výsledný obraz. a) 2 projekce; b) 4 projekce; c) 8 projekcí; d) 16 projekcí; e) 64 projekcí (s použitím filtru); f) 64 projekcí (bez použití filtru)

Zdroj: <https://www.slideshare.net/bartonect/ct-history>

Absorpce rentgenového záření pro homogenní absorbér je dána následujícím vztahem:

$$I = I_0 e^{-(\mu_1 * x_1 + \mu_2 * x_2 + \dots + \mu_y * x_y)} \quad (2.1)$$

Kde I_0 je počáteční intenzita záření před průchodem zkoumaným objektem. $\mu_1 * x$ je pak součin lineárního koeficientu zeslabení μ a tloušťky homogenní části prostředí x . Výpočet zeslabení I můžeme graficky znázornit následně:




Fig. 2.3: Výpočet zeslabení intezity záření po průchodu absorbérem.

Zdroj: <https://www.wikiskripta.eu/>

Nyní můžeme vysvětlit na jednoduchém příkladu princip jakým je dopočítána informace pro výsledný obraz CT. Předpokládejme čtverec rozdělený na čtyři

⁵ Voxel matrix element - analogie pixelu v planárním obraze. Oproti dvojrozměrnému pixelu mají voxely ještě hloubku.

homogenní absorbéry charakterizované zeslabením záření pro jednoduchost vyjádřeného $x_1 - x_4$ s danými hodnotami, jak je naznačeno na následujícím schématu:




Fig. 2.4: Zjednodušený příklad principu výpočtu zeslabení jednotlivých voxelů
Zdroj: <https://www.wikiskripta.eu/>

Hodnoty jednotlivých komponent $x_1 - x_4$ jsou pro nás ovšem neznámou. Změřit je tedy možné jen zeslabení intenzity vždy v dané rovině (hodnoty v červených a modrých obdélnících). Díky těmto hodnotám jsme ale schopni sestavit 4 rovnice o 4 neznámých:

$$\begin{aligned} x_1 + x_2 &= 4 \\ x_3 + x_4 &= 9 \\ x_1 + x_3 &= 7 \\ x_2 + x_4 &= 6 \end{aligned} \quad (2.2)$$

Touto jednoduchou soustavou rovnic jsme pak schopni dopočítat jednotlivé parametry $x_1 - x_4$.

Pokud se jedná o nehomogenní absorbér, dostává rovnice (1) tento tvar:

$$I(x) = I_0(x)e^{-\left(\int \mu(x,y)dy\right)} \quad (2.3)$$

Logaritmováním tohoto vztahu dostaneme:

$$\begin{aligned} p(x) &= -\left[\frac{I(x)}{I_0(x)}\right] \\ p(x) &= \int \mu(x,y)dy \end{aligned} \quad (2.4)$$

V praxi se ovšem při řešení úlohy vychází z přiřazení správné hodnoty absorpce jednotlivým voxelům z tzv. Radonovy transformace⁶ a zpětné Radonovy transformace, což je integrální transformace spočívající v integrování funkce přes přímky. Při výpočtu CT obrazu se používá následující tvar:

$$p(r, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y)\delta(x\cos\theta + y\sin\theta - r)dxdy \quad (2.5)$$

⁶ Autorem je Prof. Dr.phil. Johann Karl Gustav Radon narozen v Děčíně v roce 1887.

kde $f(x, y)$ reprezentuje $\mu(x, y)dy$ z rovnice (1), r je pozice zdroje rentgenového záření a θ je úhel jeho natočení. Z tohoto vztahu je pak možné odvodit zpětnou Radonovu transformaci a s jejím použitím a využitím tzv. řezového teorému je pak možné získat dokonalý obraz pro všechny úhly. Radonova transformace se ovšem v praxi ukázala jako nestabilní a tak je v praxi nahrazena metodou filtrované projekce a Fourierovy transformace.




Fig. 2.5: Princip Radonovy transformace graficky

Zdroj: https://cs.wikipedia.org/wiki/Výpočetní_tomografie

2.3.3 Hounsfieldovy jednotky

Hounsfieldova jednotka (dále HU, někdy označované jako CT číslo) je denzintní jednotka vyjadřující míru absorpce jednoho voxelu vzhledem k referenční hodnotě absorpce vody (pro vodu HU = 0). Výpočet HU je definován následujícím vztahem:

$$HU = \frac{\mu - \mu_w}{\mu_w} k \quad (2.6)$$

Kde $k = 10^3$ - je konstanta, μ - je koeficient zeslabení tkáně a μ_w - je koeficient zeslabení vody ($= 0,22\text{cm}^{-1}$). Ze vztahu (6) je patrné, že HU je bezrozměrná veličina.

Rekonstruovaný CT obraz je nejčastěji zobrazován v odstínech šedi. Po provedení počítačových výpočtů je tak možné definovat rozsah zobrazovaných dat právě rozsahem HU. Ten je pak přeškálován a vzniká tak grafická podoba CT snímku v odstínech šedi odpovídajících právě HU. Tímto je možné z naměřených dat analyzovat například pouze ty tkáně, na něž je vyšetření CT zaměřeno. Následující obrázek ukazuje vliv volby rozsahu na snímku plic:

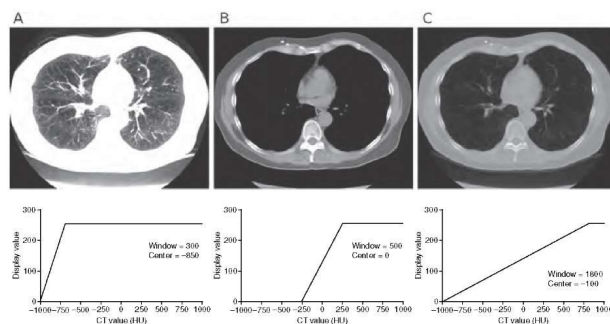


Fig. 2.6: Nsatavení rozsahu zobrazeného HU pro CT snímek plic
Zdroj: <https://www.wikiskripta.eu/>

V následující tabulce jsou pak zapsány přibližné hodnoty HU pro typické tkáně a orgány:

Tkáň	Densita HU
vzduch	-1000
tuk	-50 - (-100)
voda	0
likvor	5
bílá hmota mozková	30
šedá hmota mozková	34
krv	47
játra	40 - 60
svaly	35 - 75
vazivové tkáně	60 - 90
chrupavka	80 - 130
kost	1000 - 3000

Tab. 2.1: Orientační hodnoty HU

2.4 Magnetická rezonance

MRI je neinvazivní zobrazovací metoda založená na nukleární magnetické rezonanci. Ta využívá vlastnosti protonů, které mají určitý vlastní moment (spin) díky němuž získává celé atomové jádro určitý magnetický moment. Působením magnetického pole dochází k tomu, že se tento moment nasměruje dle působení magnetického pole. Osa jádra pak rotuje kolem myšleného vektoru, reprezentujícího směr magnetické síly. Pokud magnetické pole přestane působit, vrací se jádro do své původní klidové polohy. Pokud se přidá druhé tzv. transverzální magnetické pole, působící kolmo, jádro opět začne rotovat. V momentu kdy je transverzální pole odpojeno jádro stále ještě rotuje v rovině XY. V tomto momentu je přiblížena cívka do blízkosti rotujícího momentu, a vzhledem ke stále trvající rotaci magnetického momentu je v ní indukováno

napětí, které je možno měřit. Toto napětí a tím pádem i doba rotace po odpojení transverzálního magnetického pole jsou závislé na poloze a typu tkáně. S využitím tohoto faktu je následně z naměřených dat vypočten obraz skenovaného objektu. [5,13]

2.4.1 Historie

- 1921 - Arthur Compton objevil elektronový spin
- 1924 – Wolfgang Pauli objevil jaderný spin
- 1938 – Isidor Isaac Rabi potvrzuje magnetický kvantový jev a pojmenovává ho nukleární magnetická rezonance (NMR)
- 1945 – Dvě skupiny vědců vedené Felixem Blochem a Edwardem Purcellem nezávisle na sobě vylepšují Rabiho přístroj – zrod NMR spektroskopie
- 1973 – Paul Lauterbur – kombinace využití jevu NMR s CT metodou. Počátek tomografického MRI
- 1977 – Damadian konstruuje první celotělové MRI zařízení „Indomitable“
- 1987 – První zobrazení srdečního cyklu v reálném čase. Vývoj MR angiografie (MRA) – zobrazení toku krve
- 1992 – Zrod funkční MRI

2.5 Rozdíl mezi CT a MRT

CT	MRI
Ionizující záření (RTG)	Neionizující záření (RF vlny) + mag. pole
Informace o fyzikálních vlastnostech scény (útlum záření)	Informace o fyzikálních a chemických vlastnostech scény (hustota jader, chemické vazby, pohyb molekul, průtok, atd.)
Pouze řez v axiální rovině	Řez jakoukoliv rovinou
Vhodné pro zobrazení prvků s vyšším atomovým číslem (kosti, kalcifikované struktury, atd.)	Vhodné pro zobrazení měkkých tkání (mozek, mícha, orgány, atd.)
Vyšetření v krátkém čase	Vyšetření trvá delší dobu
Bez kontraindikací	Kontraindikace
Výborná dostupnost (nižší cena)	Menší dostupnost (vyšší cena)

Tab. 2.2: Rozdíl mezi CT a MRI

3. FORMÁT DICOM

Snímky z lékařských vyšetření jsou reprezentovány datovým formátem DICOM, což je zkratka anglického **Digital Imaging and Communications in Medicine**. Jedná se o standard pro zobrazování a také skladování dat například z MRI nebo CT vyšetření. DICOM byl vytvořen v roce 1993 výborem **DICOM Standard Committee**⁷ a jeho autorská práva vlastní asociace **NEMA** (National Electrical Manufacturers Association)⁸. Tento standard definuje způsob práce s daty a to například sdílení, mazání a jejich ukládání. Slouží také pro definici tisku, skenování a integraci do systému **PACS** (Picture Archiving and Communication System).

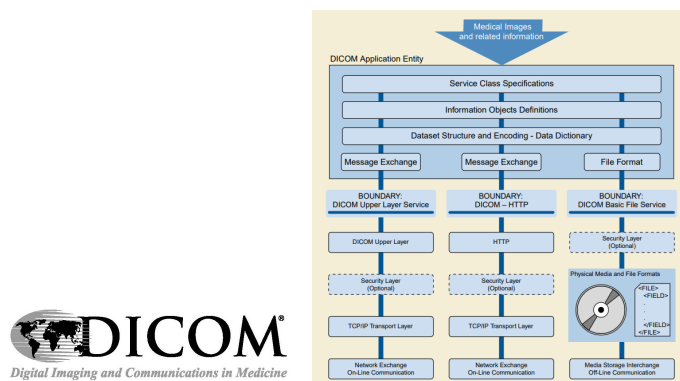


Fig. 3.1: Obecné komunikační schéma DICOM
Zdroj: <https://www.dicomstandard.org/>

Pro tuto práci je ovšem důležité, že data ukládaná standardem DICOM, neobsahují pouze vlastní obrazová data, ale mnoho metadat. Jsou to například informace o pacientovi, průběhu a typu vyšetření, datu, kdy bylo vyšetření provedeno, a pro tuto práci podstatné informace o měřítku. Jednotlivé datové soubory obsahují informace o tom, jak každý pixel v jednotlivých směrech odpovídá skutečnému rozměru.

⁷ První verze ACR/NEMA 300 byla uvolněna 1985. Následovala ARC/NEMA 2.0. V současné době je platný DICOM 3.0 z roku 1993

⁸ NEMA se rozhodla po zavedení výpočetní tomografie v 70. letech vytvořit v roce 1983 výbor pro nalezení standardu na přenos snímků a přidružených informací.

4. ITK A SIMPLE ITK

Insight Toolkit (ITK) je open-source multiplatformní systém, který poskytuje rozsáhlou sadu nástrojů pro analýzu obrazových dat [11]. ITK nabízí algoritmy pro registraci a segmentaci vícerozměrných dat i množství nástrojů pro práci s obrazovými daty (zmiňme například aplikaci metody histogram equalization, konvoluci nebo aplikaci Gaussových filtrů).



Fig. 4.1: Logo ITK a Simple ITK

Zdroj: <https://www.itk.org>, www.simpleitk.org/

Simple ITK (Insight Segmentation and Registration Toolkit) [12] nabízí zjednodušenou vrstvu postavenou na ITK, jejímž cílem je usnadnit použití v implementaci algoritmů pro zpracování obrazových dat. Hlavními charakteristikami jsou:

1. C++ knihovny
2. Objektově orientovaný nástroj
3. Poskytuje zjednodušené a snadno použitelné procedurální rozhraní bez šablon
4. Je distribuován na základě otevřené licence Apache 2.0 License.
5. Binární distribuce pro Python a Java

5. PŘÍPRAVA OBRAZOVÝCH DAT

Pro analýzu obrazových dat je často nutné vstupní obraz upravit tak, aby byla informace, kterou chceme získat, dostupnější. V následujících kapitolách jsou popsány metody přípravy obrazových dat, často označované jako preprocessing.

5.1 Histogram equalization

Do češtiny je možné název této metody přeložit jako “vyrovnání histogramu”, více se ale používá anglický název. Jedná se o metodu, která upravuje kontrast obrazu. Algoritmus je definován následujícím vztahem:

$$T^* = \operatorname{argmin}_T (|c_1(T(k)) - c_0(k)|) \quad (5.1)$$

kde c_0 je požadovaný kumulativní histogram. Na obrázcích níže je vidět jak metoda funguje. Na obrázku b) je patrné, že původně velmi úzký jasový histogram se po použití metody “roztáhne”. Z principu této metody plyne i její použití především na obrazových datech s nízkým kontrastem.

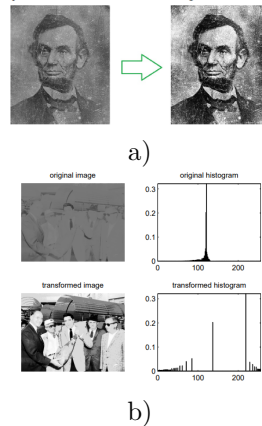


Fig. 5.1: Histogram equalization

Zdroj: *Adaptive Histogram Equalization, Histogram processing and Convolution* [23]

5.2 CLAHE

CLAHE = Contrast Limited Adaptive Histogram Equalization. Tuto metodu nejlépe popisuje následující obrázek, který vyjadřuje, jak se pracuje s histogramem:




Fig. 5.2: Contrast Limited Adaptive Histogram Equalization

Zdroj: *Adaptive Histogram Equalization, Histogram processing and Convolution* [23]

V podstatě jde o předpoklad, že v obraze nemůže být žádná hodnota jasu zastoupena s četností vyšší, než je definovaná prahová hodnota. Pokud tedy jas v histogramu tuto hranici překročí, je hodnota oříznuta a tato část je rozložena mezi ostatní jasy rovnoměrně. Ukázka CLAHE je patrná na následujícím obrázku:



Fig. 5.3: Ukázka metody Contrast Limited Adaptive Histogram Equalization

Zdroj: <http://www.sci.utah.edu/>

5.3 Vyhlazování

Většina obrazových dat, kterou chceme zpracovat, je zatížená šumem, samozřejmě se jedná i o případ snímků z CT. Tento šum může mít za následek mnohé problémy, například při registraci a potažmo i při segmentaci obrazových dat. Cílem přípravy obrazových dat je tedy tento šum v ideálním případě zcela odstranit, což ovšem není v podstatě možné, a tak je cílem obrazový šum alespoň minimalizovat.

5.3.1 Konvoluce

Myšlenka vyhlazování v obraze pro případ šumu se opírá o možnost upravit hodnotu pixelu na základě analýzy malého okolí. Jedním z prostředků odstranění šumu je rozmazání. Nevýhodou tohoto přístupu je skutečnost, že ztrácíme určitou míru informace z obrazu a problémem bývají také ostré jasové

přechody.

Pro vyhlazování se často používá diskrétní 2D konvoluce. Můžeme ji zapsat následující rovnicí:

$$g(x, y) = \sum_{m, n} h(x - m, y - n) f(m, n) \quad (5.2)$$

kde h je konvoluční maska, která udává váhu hodnot obrazové funkce daného okolí. Velmi často se používá obdélníkové nebo čtvercové okolí bodu. Nejjednodušším případem konvoluce je prosté průměrování za použití konvoluční masky:

$$h = 1/9 \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Tato konvoluční maska je pak postupně přikládána na jednotlivé pixely obrazu a je dopočítána nová hodnota jasu pixelu, která pro tuto konkrétní masku h je obyčejným aritmetickým průměrem osmiokolí bodu. Princip konvoluce je graficky naznačen i na následujícím obrázku:




Fig. 5.4: Konvoluce

Zdroj: https://commons.wikimedia.org/wiki/File:Konvoluce_2roznm_diskretni

Konvoluční maskou může být v podstatě jakákoliv matice. Následující konvoluční masky například přidávají význam pixelům blíže středu masky:

$$h = \frac{1}{10} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}; h = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}; h = \frac{1}{50} \begin{bmatrix} 1 & 1 & 3 & 4 & 3 & 1 & 1 \\ 1 & 2 & 4 & 8 & 4 & 2 & 1 \\ 1 & 1 & 3 & 4 & 3 & 1 & 1 \end{bmatrix}$$

5.3.2 Gaussův filtr

Tato metoda skládá konvoluční masku z prvků, které jsou určeny Gaussovou funkcí, tedy normálním rozdělením. Je to velmi často používaná metoda, jejímž hlavním nedostatkem je rozmazání obrazu. Masky Gaussova filtru má tedy prvky vypočtené následující rovnicí:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5.3)$$

kde σ je směrodatná odchylka. Příklad konvoluční masky h pro velikost 5×5 :

$$h = \frac{1}{273} \begin{bmatrix} 1 & 4 & 7 & 4 & 1 \\ 4 & 16 & 26 & 16 & 4 \\ 7 & 26 & 41 & 26 & 7 \\ 4 & 16 & 26 & 16 & 4 \\ 1 & 4 & 7 & 4 & 1 \end{bmatrix}$$

5.3.3 Metoda rotující masky

Máme-li konvoluční masku, je možné také použít metodu rotující masky. Mějme například masku o rozměru 3×3 , pro daný bod se maska posouvá tak, že zkoumaný bod je vždy na jiné pozici masky. Místo prostého osmiokolí je tak zkoumáno okolí o rozměru 5×5 , jak je naznačeno na následujícím schématu:




Fig. 5.5: Metoda rotující masky
Zdroj: *Guassovské filtry s rotujícím jádrem* [24]

Celkem je tedy možných 9 poloh konvoluční masky vůči zkoumanému bodu. Vybraná pro vlastní výpočet je následně ta, která má nejmenší rozptyl.

5.3.4 Nelineární filtry

5.3.4.1 Mediánový filtr

Medián je tzv 2kvantil, tedy hodnota daná stejně velkými intervaly z kumulativní distribuční funkce náhodné veličiny. Obecně tedy q – kvantil rozdělí data do q stejně velkých částí. Mějme tedy data X a hodnotu M pak pravděpodobnost $x \in X : x < M$ je rovna pravděpodobnosti jevu $x \in X : x > M$; hodnotu M pak nazýváme medián. V obrazovém vyhlazování se jedná o to, že se opět vezme n -okolí zkoumaného bodu. Hodnoty pixelů se seřadí vzestupně (může být i sestupně) a medián se určí jako prvek, který je uprostřed dané řady. Typické je použití takové matice (resp. okolí bodu), která má lichý počet prvků (3×3 ; 5×5). Výpočet je v tomto případě velmi rychlý, což je hlavní výhodou mediánové filtrace⁹, dále je výhodou značná robustnost. Naopak nevýhodou je skutečnost, že v obdélníkovém okolí porušuje tenké čáry a ostré hrany.

⁹ Výpočet je možné ještě urychlit tím, že posloupnost stačí být uspořádaná pouze částečně.

5.3.4.2 Konzervativní vyhlazení

Tento filtr slouží především k odfiltrování izolovaných pixelů s výjimečně vysokou nebo nízkou intenzitou. Nalezneme tedy minimum a maximum v okolí bodu a pokud je hodnota v rozmezí definovaném zmíněným rozsahem, je ponechána. Pokud je hodnota pod minimem, je nahrazena hodnotou právě minima a analogicky tato úvaha platí pro překročení maxima okolí bodu. Tento typ je vhodný především pro odstranění šumu typu "sůl" nebo "rýže".

5.3.4.3 Prahování vlnkových koeficientů

Nejprve je spočítána hodnota jednotlivých bodů pomocí diskrétní vlnkové transformace a dále se volí buď tvrdé prahování:

$$\rho_{\lambda}^{tvrdé}(x) \begin{cases} x & |x| \geq \lambda \\ 0 & |x| < \lambda \end{cases}$$

nebo měkké

$$\rho_{\lambda}^{měkké}(x) \begin{cases} x - \lambda & x \geq \lambda \\ x + \lambda & x \leq -\lambda \\ 0 & |x| < \lambda \end{cases}$$

5.3.4.4 Bilaterální filtr

Metoda¹⁰, která vykazuje velmi dobré výsledky, ovšem to je kompenzováno časovou náročností. Hlavní výhodou je zachování významných jasových přechodů (hran) v obraze a naopak filtrace šumu na souvislých plochách. Filtr pracuje na principu průměrování hodnot bodu pouze z okolních bodů s podobnou hodnotou. Pro body s nízkou jasovou hodnotou uvažuje pro průměrování pouze body s podobně nízkými jasovými hodnotami a tím tmavá místa nezesvětluje a zachovává ostrost hrany.¹¹

¹⁰ Bilaterální filtr byl prezentován už v roce 1998 dvojicí Tomasi a Manduchi.

¹¹ V barevném prostoru je nutné převést obraz do barevného prostoru CIE-LAB. Nepostačují totiž pouze tři kanály RGB reprezentace.

5.3.5 Ukázka použití některých filtrů

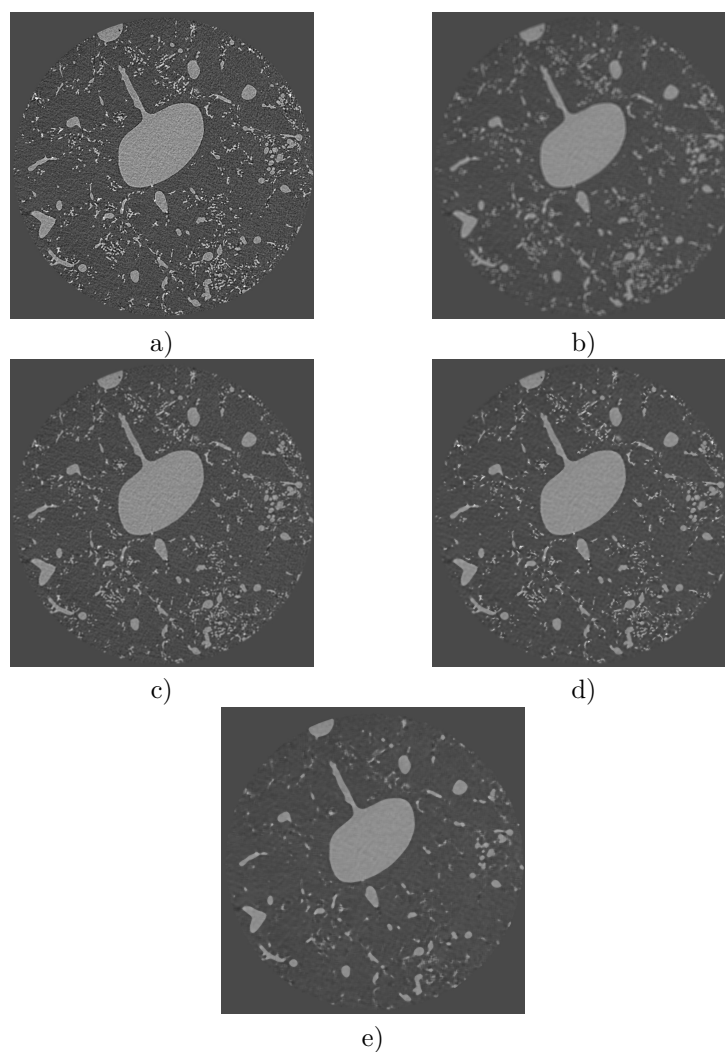


Fig. 5.6: Vyhlazování šumu - a) původní obraz; b) průměrování; c) Gaussův filtr; d) bilaterální filtr; e) medián pro masku velikosti 11x11

V následující tabulce jsou zobrazeny časy potřebné k výpočtení filtrovaného obrazu za použití jednotlivých filtrů. Pro filtraci obrazu byla využita knihovna OpenCV v Pythonu. Běh algoritmu může být ovlivněn procesy běžícími na pozadí operačního systému, a tak mohou být časy zkreslené.

Metoda	Velikost masky	Čas/s
Průměrování	11x11	34,01
Průměrování	3x3	6,58
Gaussův filtr	11x11	36,60
Gaussův filtr	3x3	6,71
Medián	11x11	19,12
Medián	3x3	7,01
Bilaterální filtr	11x11	43,14
Bilaterální filtr	3x3	10,95

Tab. 5.1: Časová náročnost pro jednotlivé metody

Pozn.: Časy jsou měřeny pro CT snímky (750 snímků o celkové velikosti 380MB.)

6. SEGMENTACE

Segmentace slouží k rozdělení obrazu na několik částí (segmentů), které mají společné vlastnosti. Metod, které se dají za tímto účelem použít, je celá řada, některé jsou popsány v následujících kapitolách. Cílem je najít na obraze nějaký konkrétní objekt nebo například identifikovat popředí a pozadí. Segmentaci obecně je možné chápat jako úlohu rozdělení obrazu do segmentů s podobnými vlastnostmi. Kromě zpracování snímků v oblasti medicíny se segmentace používá například při dálkovém průzkumu země nebo trackování objektů na snímcích kamer.

Segmentaci obrazu můžeme zapsat pro \mathbb{R}^2 prostor ve kterém mějme obraz $f(x, y)$ jako rozdělení na R_{orig} na R_1, R_2, \dots, R_n částí, které splňují následující kritéria:

1. $\bigcup_{i=1}^n R_i = f(x, y)$
2. $R_i \cap R_j = \emptyset, i \neq j$
3. $\forall f(x, y), x, y \in R_i; f(i, j), i, j \in R_i : f(x, y) = f(i, j) \pm \alpha$

, kde α je rozsah hodnot pixelů v daném segmentu ¹²

6.1 Prahování

Prahování (anglicky *thresholding*) je metoda, ve které jsou jasové hodnoty vyšší než definovaný práh považovány za popředí obrazu a všechny body s hodnotou jasu nižší naopak za pozadí (případně obráceně). Jedná se tedy o jasovou transformaci vstupního obrazu f na výstupní binární obraz g . Mějme prahovou hodnotu T potom:

$$g(i, j) = \begin{cases} 1 & f(x, y) \geq T \\ 0 & f(x, y) < T \end{cases} \quad (6.1)$$

Obecně je možné zavést nikoliv jeden práh T , ale několik prahů pro jeden obraz. Za tohoto předpokladu $T_1 < T_2 < T_3 < \dots < T_m$ platí:

$$g(i, j) = \begin{cases} n & f(x, y) \geq T_m \\ \dots \\ 2 & f(x, y) \geq T_2 \wedge f(x, y) < T_3 \\ 1 & f(x, y) \geq T_1 \wedge f(x, y) < T_2 \\ 0 & f(x, y) < T_1 \end{cases} \quad (6.2)$$

¹² Podmínku 3) je možné zapsat i jinými způsoby, dle typu segmentace.

Dále je možné uvažovat i prahování jednostranné nebo oboustranné. Pro dvě prahové hodnoty platí u oboustranného prahování, že prahovaný obraz bude mít hodnotu jedna pouze pokud je hodnota jasu mezi danými hranicemi. Jinak bude hodnota výsledného obrazu 0.

6.1.1 Non-maximal supression

Důležitým aspektem úspěšného použití prahování při segmentaci obrazu je určení prahové hodnoty, ta se často získává na základě analýzy histogramu. Metoda non-maximal supression (česky *potlačení nemaxim*) je rychlou a účinnou metodou nalezení lokálních maxim. Ta je pak možné využít právě k určení prahové hodnoty. Jak metoda funguje, je patrné na následujícím schématu:

1	-1	5	4	10	2	1
1	-1	5	4	10	2	1
1	-1	5	4	10	2	1
1	-1	5	4	10	2	1
1	-1	5	4	10	2	1


Fig. 6.1: Non-maximum supression

Zdroj: *Adaptive Histogram Equalization, Histogram processing and Convolution [23]*


Metoda po zkoumaném obraze (histogramu) posouvá okénko, a dívá se, jestli je bod v centru maximem v rámci okolí. Pokud ne, posouvá okénko dále. Pokud ano, metoda označuje tento bod za lokální maximum. Zřejmou nevýhodou je potřeba mít dostatečně velké okénko.




a)



a)



b)



c)

Fig. 6.2: Non maximum supression s vyznačenými maximy v histogramu pro a) příliš malé okénko - velmi mnoho lokálních maxim; b) rozumnou hodnotu c) příliš velké okénko - pouze jedno lokální maximum = globální maximum

6.1.2 Adaptivní prahování

Adaptivní prahování je realizováno tak, že je práh funkcí polohy v obraze, jinými slovy můžeme říct, že je práh určován vždy pro část obrazu. Podobně jako u předešlé metody je nezbytné správně určit velikost oblasti, pro níž je práh určován. V případě, že jsou jednotlivé části disjunktní, může docházet ke vzniku nežádoucích artefaktů na přechodech jednotlivých oblastí. Tento problém se dá řešit buďto částečným překryvem oblastí, interpolací nebo počítat pro oblast kolem každého obrazového bodu (tato možnost vede na velkou časovou náročnost).

Metoda adaptivního prahování se využívá například pro obrazová data s nevyrovnanými jasovými oblastmi, ty mohou vzniknout například nerovnoměrným osvětlením snímaného objektu.

6.1.3 Otsu

Metoda slouží k nalezení ideální hodnotu prahu pro bimodální histogram¹³. Předpokládá tedy dva vrcholy histogramu a práh se pak hledá takový, který minimalizuje vážený rozptyl σ_W dvou jasových tříd. Ekvivalentně je možné zapsat jako maximalizaci rozptylu jednotlivých tříd. Mějme tedy dvě třídy $C_0 \in 1, 2, 3, \dots, k, C_1 \in k + 1, \dots, L$ potom:

$$p_i = \frac{n_i}{N}, p_i \geq 0, \sum_{i=1}^L p_i = 1 \quad (6.3)$$

$$\omega_0 = Pr(C_0) = \sum_{i=1}^k p_i = \omega(k) \quad (6.4)$$

$$\omega_1 = Pr(C_1) = \sum_{i=k+1}^L p_i = 1 - \omega(k) \quad (6.5)$$

nyní definujme průměry obou skupin:

$$\mu_0 = \sum_{i=1}^k i Pr(i|C_0) = \sum_{i=1}^k \frac{ip_i}{\omega_0} = \frac{\mu(k)}{\omega(k)} \quad (6.6)$$

$$\mu_1 = \sum_{i=k+1}^L i Pr(i|C_1) = \sum_{i=k+1}^L \frac{ip_i}{\omega_1} = \frac{\mu_T - \mu(k)}{1 - \omega(k)} \quad (6.7)$$

a celkový jasový průměr:

$$\mu_T = \mu(L) = \sum_{i=1}^L iP_i \quad (6.8)$$

¹³ Metoda pojmenována po japonském matematikovi jménem Nobuyuki Otsu.

Nyní definujeme variace pro obě skupiny:

$$\sigma_0^2 = \sum_{i=1}^k (i - \mu_0)^2 Pr(i|C_0) = \sum_{i=1}^k (i - \mu_0)^2 \frac{p_i}{\omega_0} \quad (6.9)$$

$$\sigma_1^2 = \sum_{i=k+1}^L (i - \mu_1)^2 Pr(i|C_1) = \sum_{i=k+1}^L (i - \mu_1)^2 \frac{p_i}{\omega_1} \quad (6.10)$$

dále platí:

$$\omega_0 \mu_0 + \omega_1 \mu_1 = \mu_T \quad (6.11)$$

$$\omega_0 + \omega_1 = 1 \quad (6.12)$$

Nyní zapišme kritérium optimality, které vychází z diskriminační analýzy:

$$\lambda = \frac{\sigma_B^2}{\sigma_w^2}; \quad \kappa = \frac{\sigma_T^2}{\sigma_w^2}; \quad \eta = \frac{\sigma_B^2}{\sigma_T^2} \quad (6.13)$$

pro σ_T^2 , σ_w^2 a σ_B^2 platí:

$$\sigma_w^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 \quad (6.14)$$

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 = \omega_0 \omega_1 (\mu_1 - \mu_0)^2 \quad (6.15)$$

$$\sigma_T^2 = \sum_{i=1}^L (i - \mu_T)^2 p_i \quad (6.16)$$

Vzhledem k tomu, že kritéria σ_T^2 , σ_w^2 a σ_B^2 jsou navzájem závislá, neboť platí $\sigma_w^2 + \sigma_B^2 = \sigma_T^2$ stačí maximalizovat pouze jedno z kritérií a výsledné řešení bude optimální. Vzhledem k tomu, že je pro něj výpočet nejjednodušší, zvolme kritérium η . Pro něj pak můžeme zapsat:

$$k^* = \operatorname{argmax}_{1 \leq k < L} \sigma_B^2(k) \quad (6.17)$$

kde k^* je hledaný optimální práh a pro σ_B^2 platí:

$$\sigma_B^2 = \frac{[\mu_T \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (6.18)$$

6.1.3.1 Procentní prahování

Vychází z faktu, že máme apriorní informaci, jakou procentuální část zabírají jednotlivé segmenty, co se jejich plochy týče. Uvažujme opět šedotónový obraz definovaný pro jednotlivé pixely pouze jejich jasovou hodnotou a bimodální histogram, respektive jeden objekt do popředí. O zkoumaném obrazu víme, že hledaný objekt v popředí tvoří 11 % celkové plochy obrazu. Prah je tedy nastaven právě tak, aby 11 % jasových hodnot v histogramu bylo nad tímto prahem.

6.1.4 Další určení prahu

Práh může být samozřejmě určen i pomocí dalších metod. Vůbec nejjednodušší metodou je experimentální zadání prahové hodnoty například uživatelem. Posloužit k určení prahu samozřejmě mohou i další statistické údaje, jako je například střední hodnota, medián, atp. Výše uvedené algoritmy jsou ovšem funkční a nejčastěji používané.

6.1.5 Výsledky jednotlivých metod

Z následující série obrázků je patrné, jak se zachovají jednotlivé výše popsané metody pro různě nastavené hodnoty na vstupním zašuměném obraze z mikroCT jater.




Fig. 6.3: Prahování - a) původní obraz; b) adaptivní prahování pro okénko 11x11; c) adaptivní prahování pro okénko 121x121; d) adaptivní prahování pro okénko 501x501; e) Otsu prahování; f) Percentní prahování pro 15 %; g) Percentní prahování pro 85 %

6.2 Detekce hran

Nejprve definujme, co je to hrana. V obraze je hrana místem, kde dochází k nespojitosti v barvě, jasu, případně textuře nebo jiných obrazových parametřích. Segmentace s pomocí detekce hran využívá právě této vlastnosti a úvahy, že každý objekt v obraze bude ohraničen hranou.

6.2.1 Využití znalosti polohy hranic

Pokud obraz, na němž se snažíme hrany detekovat, předzpracujeme například prahováním, je možné uvažovat jistou apriorní informaci minimálně o pravděpodobné poloze hrany a také jejímu tvaru. Tyto informace můžeme získat aplikací segmentace na obraze s nižším rozlišením. Můžeme také využít polohu významných hranových buněk. Pokud tedy máme nějakou takovou apriorní informaci o pravděpodobné poloze a tvaru hranice, může proložit aproximační křivkou a tím hranici zpřesnit.

6.2.2 Postupné dělení spojnic

Tato metoda pracuje se vstupem, který tvoří obraz a koncové body hranice. Zároveň je nezbytné, aby zkoumaný obraz neobsahoval příliš mnoho šumu. Dalším předpokladem je tvar hranice. Tuto metodu použijeme, pokud nepředpokládáme příliš zakřivenou hranici. Principem metody je vytvoření spojnice mezi každými dvěma body na hranici. Uprostřed této spojnice nalezneme normálu, a právě na ní hledáme další body ležící na hledané hranici. Z nalezených bodů vezmeme ten, který je nejbližší spojnici mezi již detekovanými body a má nadprahovou délku hrany. Tento bod se pak stává nový hraničním bodem. Tento proces se opakuje - jedná se tedy o iterační metodu.

6.2.3 Cannyho hranový detektor

Tato metoda předpokládá málo zašuměný obraz, ten je samozřejmě vhodné předzpracovat vhodnou filtrační metodou. Někdy se přímo v algoritmu Cannyho hranového detektoru využívá Gaussův filtr (popsaný v kapitole 5.3.2). Dalším krokem je výpočet první derivace - gradientu. V tomto případě se často používá Sobelův operátor. Jeho hlavními výhodami je relativně nízká citlivost na šum a také skutečnost, že kromě velikosti gradientu, který reprezentuje hranu, vrací také její směr. Sobelův operátor má pro velikost 3x3 následující tvar:

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, h_3 = \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix}, \dots$$

Následně jsou nalezena lokální maxima. V praxi se toto provádí metodou Non-maximum suppression (popsanou v kapitole 6.1.1). Tento krok zajišťuje nalezení hrany v místě největšího gradientu a je někdy také označován jako *Thinning - ztenčení*.

Nyní tedy máme v obraze označeny všechny hrany bez ohledu na jejich vlastnosti a význam. V posledním kroku tohoto algoritmu jsou vybrány pouze významné hrany. Určíme tedy dva prahy $T_1 < T_2$. Pro jednotlivé body $f(x, y)$:

$$(x, y) \begin{cases} f(x, y) \geq T_2 & x, y \text{ je hranový bod} \\ T_1 \leq f(x, y) < T_2 & x, y \text{ je hranový pokud } \exists \text{ sousední hranový bod} \\ T_1 \leq f(x, y) < T_2 & x, y \text{ není hranový pokud } \nexists \text{ sousední hranový bod} \\ f(x, y) < T_1 & x, y \text{ není hranový} \end{cases}$$

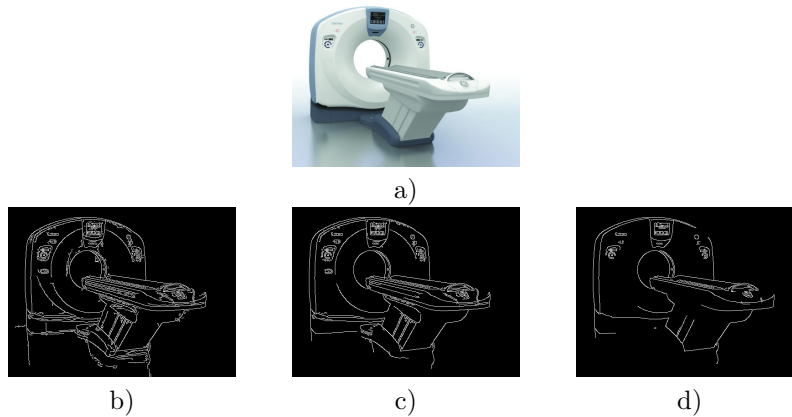


Fig. 6.4: Cannyho hranový detektor - a) původní obraz - CT ; b) nastavení prahů na $T_1 = 10$ a $T_2 = 50$; c) nastavení prahů na $T_1 = 20$ a $T_2 = 100$; d) nastavení prahů na $T_1 = 100$ a $T_2 = 200$

6.2.4 Derivace a konvoluční masky

V předchozí kapitole bylo popsáno použití Sobelova operátoru k nalezení hran. Sobelův operátor samozřejmě není jediný, který je možné použít. Další konvoluční masky jsou například **Robertsův operátor** 2×2 :

$$h_1 = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

Gradient je pak vypočítán následně:

$$|g(x, y) - g(x + 1, y + 1)| + |g(x, y + 1) - g(x + 1, y)| \quad (6.19)$$

Nevýhodou tohoto operátoru je vysoká citlivost na šum vstupního obrazu. Důvod je zřejmý, vzhledem k tomu, že zkoumané okolí je velmi malé, má velký vliv na výpočet každý zkoumaný bod obrazu.

Dalším je **Operátor Prewittové**, který má pro okolí 3×3 následující tvar:

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \dots$$

Robinsonův operátor 3×3 pak vypadá následně:

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}, h_2 = \begin{bmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{bmatrix}, h_3 = \begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix}, \dots$$

Jistě ne posledním ale posledním operátorem, který zmíníme, je **Kirschův operátor** pro okolí 3×3 :

$$h_1 = \begin{bmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{bmatrix}, h_2 = \begin{bmatrix} 3 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & -5 & 3 \end{bmatrix}, h_3 = \begin{bmatrix} -5 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & 3 & 3 \end{bmatrix}, \dots$$




a)




b)




c)



d)



e)



f)



g)

Fig. 6.5: Prahování - a) původní obraz - CT ; b) Sobelův operátor h_1 ; c) Sobelův operátor h_2 ; d) Sobelův operátor h_3 ; e) Prewitt operátor; f) Kirschův operátor; g) Robinsonův operátor

Pozn.: Všechny konvoluce se všemi operátory d) - g) provedeny s h_1 maskou popsanou výše.

6.2.5 Aktivní kontury

Tato metoda na svém vstupu požaduje mít uzavřenou křivku kolem segmentu, který je nezbytné určit přesně. Je to tedy metoda sloužící především pro zpřesnění výsledků nějaké hrubší segmentace. Hranice je zpřesňována otevřenou nebo uzavřenou spline funkcí (snake)¹⁴. Metoda pracuje na principu

¹⁴ Definována D.T. Sandwellem v roce 1987.

minimalizace energie z části určené energií segmentu pod spline funkcí a z druhé části energií křivky získané právě spline funkcí. Tato metoda je vhodná i pro zašuměná data, hlavní nevýhodou je potřeba specifikovat oblast, v níž se segment snažíme nalézt.

6.2.6 Watershed segmentation

Do češtiny můžeme přeložit jako *registrace povodím*. Jak je uvedeno ve článku *Medical image segmentation by marker controlled watershed and mathematical morphology [25]*, jedná se o rychlou, robustní a často používanou segmentační metodu. Metoda uvažuje obraz jako krajinu, kde jasové hodnoty v podstatě určují nadmořskou výšku jednotlivých bodů. Do této krajiny je pak vlita imaginární voda. Segmenty se stejnou nadmořskou výškou (jasovou hodnotou) jsou pak naplněny vodou a hrany se pak nalézají na hranicích jednotlivých segmentů.




Fig. 6.6: Watershed segmentation

Zdroj: *Medical image segmentation by marker controlled watershed and mathematical morphology [25]*

6.2.7 Houghova transformace

Metoda původně vznikla pro hledání přímk v obraze. Obecně ale s použitím Houghovy transformace (HT) jsme schopni nalézt objekty daného tvaru. HT je vhodná pro zašuměné objekty a použitelná i tehdy, je-li v obraze část hledaného objektu zakryta. Nevýhodou je, že musíme znát tvar hledaného objektu. Další nevýhodou HT je poměrně malá rychlost a nepřesnosti vzniklé zkráslením objektů.

Princip popíšme na jednoduchém hledání přímky v \mathbb{R}^2 prostoru. Každá přímka v dvojrozměrném prostoru je určena vzdáleností od středu souřadného systému a úhlem, který svírá s jednou z os, řekněme s osou x . Tento úhel označme σ . Každá přímka je tedy dána dvojicí (r, σ) neboť rovnice přímky je:

$$x \cos(\sigma) + y \sin(\sigma) = r \quad (6.20)$$

Mějme tedy opět prostor \mathbb{R}^2 s osami r a σ . V takovém prostoru se pak každá jedna přímka zobrazí jako jediný bod. Pokud máme v prostoru s osami x, y

definován libovolný bod, můžeme nalézt množinu přímek, které tímto bodem procházejí. Pokud tyto přímky budeme postupně dosazovat do rovnice (6.20), dostaneme v prostoru r, σ sinusovku. Pro každý bod x, y pak můžeme vykreslit v prostoru r, σ takovou sinusovku. Přímku procházející všemi těmito body pak nalezneme jako průnik sinusovek v prostoru r, σ .




Fig. 6.7: Houghova transformace pro nalezení přímek v 2-D obraze
Zdroj: https://scikit-image.org/docs/stable/auto_examples/

6.3 Narůstání oblastí - Region growing

Metoda Region growing (RG) pracuje na principu rozdělení obrazu do ploch, které jsou homogenní, a to v předem definovaném kritériu nebo vlastnosti. Touto vlastností může být v podstatě cokoli od hodnoty jasové intenzity pixelu až po sofistikované komplexní popisy. Výhodou RG je možnost použití na zašuměné oblasti, kde je obtížné hledat hranice. RG pracuje jednoduše na porovnání pixelu se sousedy. Homogenitu bodu X určíme následně:

$$X \left\{ \begin{array}{l} H(R_i) = \text{HOMOGENNÍ} \\ H(R_i \cup R_j) \neq \text{HOMOGENNÍ} \end{array} \right. \left| \begin{array}{l} \forall i \in \langle 1, 2, \dots, I \rangle \\ \forall i, j \in \langle 1, 2, \dots, I \rangle \ i \neq j \wedge R_i \text{ soused } R_j \end{array} \right. \quad (6.21)$$

Příčemž I je počet oblastí, R_i a R_j jednotlivé oblasti a $H(R_i)$ pak vyjadřuje homogenitu.

6.4 Náhodné Markovské řetězce

S Markovskými řetězci se nejčastěji setkáváme při práci s náhodnými procesy. Proces můžeme za Markovský řetězec označit, platí-li: *pravděpodobnost přechodu do následujícího stavu závisí pouze na stavu současném (nikoliv na stavech předchozích)*. V oblasti práce s obrazy tak můžeme použít stejnou myšlenku: *význam bodu je závislý jen a pouze na významech bodů přímo sousedících*. Mějme tedy pixel x a ten je definovaný svým příznakem, respektive příznakovým vektorem \vec{f}_x . Tímto příznakem může být opět obecně cokoli, nejjednodušší je použití jasů příslušného bodu. Dále mějme množinu všech příznaků, resp. příznakových vektorů:

$$f = \{\vec{f}_x : x \in \mathbf{I}\} \quad (6.22)$$

Dále mějme množinu všech označení (labelů) $\mathbf{L} = \{\text{pozadí, popředí}\}$. Každý prvek množiny \mathbf{L} je přiřazen k x a nazýváme jej skrytou proměnnou. Máme-li obraz o rozměrech $A \times B$ pak máme $|\mathbf{L}|^{A \times B}$ možných výsledků. Tuto hodnotu označme $|\Omega|$. Cílem segmentační úlohy je samozřejmě z množiny všech možných řešení vybrat to správné na základě pravděpodobnostní míry. Hledáme tedy w^* maximalizující podmíněnou pravděpodobnost $P(w|f)$. Platí: $w = \{w_x : x \in \mathbf{L}\}$ a hledáme tedy odhad maximální a posteriori pravděpodobnosti (MAP):

$$w^{*MAP} = \operatorname{argmax}_{w \in \Omega} P(w|f) \quad (6.23)$$

S využitím Bayesova pravidla můžeme zapsat:

$$P(w|f) = \frac{P(f|w)P(w)}{P(f)} \quad (6.24)$$

Vzhledem k tomu, že $P(f)$ je konstantní, můžeme dělitele předchozí rovnice vynechat. Tímto krokem a dosazením převádíme na úlohu optimalizace minimální energie dat + energie spojitosti. V praxi je náhodné pole často definováno jako graf a následně použita metoda Graph-Cut.

6.5 Metody založené na zkoumání tvaru

6.5.1 Metoda založená na vlastních číslech Hessovy matice - Frangiho filtr

Hessova matice je maticí druhých parciálních derivací skalární funkce a má následující tvar:

$$H(f) = \begin{vmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \cdots & \cdots & \cdots & \cdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{vmatrix} \quad (6.25)$$

Frangiho segmentační filtr pracuje s faktem, že cévy jsou válcovité struktury. Pro každý jeden voxel tedy zkoumá okolí a analyzuje, zda se jedná o válcovité struktury, popřípadě struktury jiného tvaru.

Hessovu matici používá jako konvoluční filtr. Následně provedeme dekompozici na vlastní vektory. Vzhledem k tomu, že je použita matice 3×3 , dostaneme pro každý voxel obrazu tři vlastní vektory. Tato sada vektorů reprezentuje zkoumaný voxel v novém ortonormálním souřadnicovém systému a obsahuje informaci o zakřivení zkoumaného obrazu. Vlastní čísla kvantifikují velikost zakřivení v jednotlivých směrech a je tedy možné je použít pro hledání různých typů struktur (viz tabulka 6.5.1). Díky tomu je možné najít cévám podobné struktury v obraze na základě zkoumání vlastních vektorů Hessovy matice.

Mějme tedy vlastní čísla $\lambda_1 \leq \lambda_2 \leq \lambda_3$. Cévy nebo obecněji válcovité struktury pak odpovídají myšlence, že ve dvou směrech je zakřivení velké a ve třetím směru naopak malé. tj.:

$$|\lambda_1| \approx 0, |\lambda_1| \ll |\lambda_2|, |\lambda_3| \quad (6.26)$$

Pro usnadnění klasifikace jednotlivých struktur je ve Frangiho filtru definováno několik významných poměrů:

$$R_A = \frac{|\lambda_2|}{|\lambda_3|} \quad (6.27)$$

rozlišuje válcovitých od deskovitých struktur. Jak bylo zmíněno výše λ_2 a λ_3 jsou v případě cév téměř stejně velké a hodnota λ_1 je naopak malá po celé délce struktury. Pokud se jedná o plochou deskovitou strukturu, jsou první dvě hodnoty malé (tj. λ_1 a λ_2) a pouze hodnota λ_3 je výrazně vyšší. Pokud se tedy jedná o válcovitou, cévám podobnou, strukturu, blíží se poměr R_A hodnotě 1. Naopak pokud bude hodnota tohoto poměru v blízkosti 0, jedná se o plochou strukturu.

Definujme dále poměr R_B :

$$R_B = \frac{|\lambda_1|}{\sqrt{|\lambda_2||\lambda_3|}}, \quad (6.28)$$

díky němuž je možné oddělit válcovité a kulovité struktury. Kulovité struktury mají vlastní čísla Hessovy matice zhruba stejně velká. R_B tedy dosahuje svého maxima blížícího se 1 právě pro kulovité struktury, zatímco pro ostatní hodnotu blížící se 0.

Další informaci o struktuře a tvaru můžeme získat z tzv. *Frangi's structureness measure* (v češtině možno říci Frangiho míru strukturality):




$$S = \|H\|_F = \sqrt{\sum_{j \leq D} \lambda_j^2} = \sqrt{\lambda_1^2 + \lambda_2^2 + \lambda_3^2} \quad (6.29)$$

Tato míra je Frobeniovou normou matice a díky ní můžeme oddělit šum a strukturu nebo oblast zájmu. Frobeniova norma uvažuje velikost všech tří vlastních čísel, z nichž pro libovolnou strukturu bude minimálně jedno obsahovat vysokou hodnotu narozdíl od šumu.

Frangiho celková míra podobnosti cévní struktuře je pak spočítána následujícím způsobem:

$$V(x, s) = \begin{cases} 0 & \text{pokud } \lambda_2 > 0 \text{ nebo } \lambda_3 > 0 \\ (1 - \exp(\frac{-R_A^2}{2\alpha^2})) \exp(\frac{-R_B^2}{2\beta^2}) (1 - \exp(\frac{-S^2}{2\gamma^2})) & \text{jinak} \end{cases} \quad (6.30)$$

Kde α, β a γ jsou prahové hodnoty definující citlivost Frangiho filtru na jednotlivé typy struktur a šum. Dle definice Frangiho míry 6.30 jsou také zanedbány voxely, pro něž jsou vlastní čísla matice λ_2 a λ_3 větší než 0. Právě tato vlastnost indikuje, že se jedná o voxely s nízkou optickou absorpcí na pozadí. Pro přehlednost je význam jednotlivých vlastních čísel Hessovy matice uveden v následující tabulce:

λ_1	λ_2	λ_3	Tvar struktury	
malé	velké	velké	válcovitá	
malé	malé	velké	plochá, talířovitá	
velké	velké	velké	kulovitá	

Tab. 6.1: Souvislost velikosti vlastního čísla s tvarem zkoumané struktury

Frangiho filtr je vhodné použít opakovaně v různých měřítkách a různém natočení Hessovy matice v 3D obraze. Výsledky jednotlivých filtrací jsou pak zkombinovány, celková míra důvěry ve skutečnost, že se jedná o cévu, je spočtena dle následujícího vztahu:

$$\hat{V}(x) = \max_{s_{min} \leq s \leq s_{max}} v(x, s) \quad (6.31)$$

6.5.2 Gaborovy filtry a K-means

K segmentaci cév v obraze se často využívá Gaborových filtrů. Tato metoda je často využívaná pro segmentaci cév sítnice [26–28]. Metoda vychází z myšlenky, že každá textura obsahuje úzkou oblast frekvenčních a orientačních složek. Vstupní obraz je filtrován pásmovou propustí s nastavitelnou středovou frekvencí, šířkou pásma a orientací. Gaborův filtr je definován sinusovou vlnou vynásobenou Gaussovou funkcí. Platí, že Fourierova transformace impulzní odezvy Gaborova filtru je konvolucí Fourierovy transformace harmonické funkce a Fourierovy transformace Gaussovy funkce. Filtr má reálnou a imaginární složku, které můžeme vyjádřit komplexním tvarem:

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi \frac{x'}{\lambda} + \psi\right)\right) \quad (6.32)$$

Nebo pro jednotlivé složky zvlášť:

$$g_{real}(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(\left(2\pi \frac{x'}{\lambda} + \psi\right)\right) \quad (6.33)$$

$$g_{imag}(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \sin\left(\left(2\pi \frac{x'}{\lambda} + \psi\right)\right) \quad (6.34)$$

kde

$$x' = x \cos \theta + y \sin \theta; \quad y' = -x \sin \theta + y \cos \theta \quad (6.35)$$

λ reprezentuje vlnovou délku sinusového faktoru, θ úhel normály vůči rovnoběžným pruhům Gaborovy funkce, ψ je fázový offset, σ standardní odchylka Gaussovy obálky a γ poměr prostorových aspektů.

V praxi je vytvořena databáze Gaborových filtrů, které jsou použity jako konvoluční jádro pro vstupní obraz. Tím jsou data převedena do tzv. Gaborova prostoru, z něž je možné extrahovat vlastnosti užitečné pro segmentaci obrazu.




Fig. 6.8: Příklad Gaborova filtru - a) Prostorová reprezentace reálné části; b) Reálná část; c) imaginární část

Zdroj: *Retinal Vessel Segmentation Using the 2-D Morlet Wavelet and Supervised Classification* [27]

Pro segmentaci jednotlivých odlišných textur na základě vlastností získaných konvolucí obrazu s Gaborovými filtry se často používá metoda *K-means*. Jedná se o algoritmus nehierarchické shlukové analýzy. Algoritmus předpokládá, že je na začátku znám počet shluků (k) a vlastnosti objektů jsou body v eukleidovském prostoru. Shluky jsou reprezentovány tzv. *centroidy*. K -centroidů je na začátku umístěno náhodně do prostoru a jednotlivé objekty se přiřadí k nejbližšímu centroidu. V dalším kroku dojde k přepočtení pozice centroidů tak, aby ležely v těžišti jednotlivých shluků. Tyto kroky se opakují, dokud algoritmus nedojde k ustálení (konvergenci).

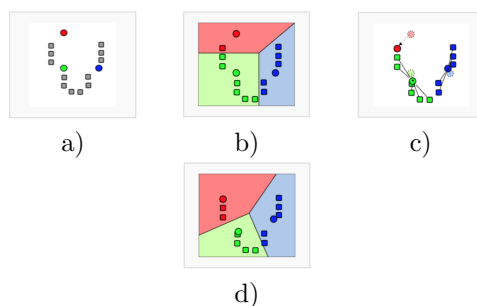


Fig. 6.9: Demonstrace algoritmu K-means - a) Inicializace - náhodné umístění centroidů; b) Přiřazení objektů do k shluků; c) posunutí centroidů do těžiště shluku; d) kroky b) a c) se opakují, dokud nedojde k ustálení.

Zdroj: <https://brilliant.org/wiki/k-means-clustering/>

6.6 Metoda Graph-Cut

Tato metoda využívá teorie grafů [20] a převádí segmentační problém na úlohu nalezení maximálního toku, respektive minimálního řezu v grafu. Její použití v segmentačních úlohách popsal například Boykov [18, 19], implementovat ji lze například v MATLABu [21] nebo pomocí ITK [22]. Nejprve je obraz převeden na graf $G(V, E)$, kde V je množina vrcholů a E množina hran, které reprezentují sousednost obrazových bodů. Vrcholy odpovídají vlastním pixelům. Množina vrcholů je navíc ještě rozšířená o *terminály*. Těmi jsou *zdroj* a *spotřebič*. Tyto dva uzly jsou spojené se všemi ostatními vrcholy.

Graph-cut metodu si můžeme představit jako potrubí [21], hrany odpovídají trubkám s danou kapacitou a uzly grafu jejich spojnicemi, koleny nebo místy, kde se potrubí kříží. Segmentaci si potom můžeme představit jako vpouštění kapaliny do potrubí zdrojem a její protékání soustavou až do spotřebiče. Pokud se někde tekutina v potrubním systému hromadí, dochází k tzv. *saturaci*. Neustálým vpouštěním kapaliny se dostaneme do stavu, kdy systém již další množství kapaliny nepojme a vpouštěná kapalina se tak již nemůže dostat ke spotřebiči. Tento moment je v podstatě zastavovací podmínkou algoritmu. Pozadí a segmentovaný objekt (popředí) jsou pak vzájemně odděleny saturovanými hranami.

Vzhledem k tomu, že hledání minimálního řezu je úlohou minimalizace energetické funkce, můžeme zapsat:

$$C(L) = \lambda R(L) + B(L) \quad (6.36)$$

Přičemž $R(L)$ reprezentuje míru podobnosti zkoumaných obrazových bodů s pozadím nebo popředím (segmentovaným objektem) a $B(L)$ je ohodnocení hrany v obraze mezi obrazovými body. L značí příslušnost k pozadí nebo popředí (segmentovanému objektu).

Metoda Graph-Cut je vhodná především pro interaktivní segmentaci s využitím uživatelského vstupu. Interakce uživatele spočívá v označení seedů (voxelů reprezentujících popředí a pozadí v obraze), následně je provedena segmentace. Uživatel pak v dalším kroku může z již segmentovaných dat vybrat další seedy pozadí a hledaného objektu, které byly v předchozím kroku nesprávně označeny. Takto se iterativním procesem můžeme dostat poměrně rychle a uživatelsky přívětivě k velmi přesnému řešení segmentační úlohy.

7. REGISTRACE OBRAZOVÝCH DAT

Problém fúze obecně N snímků s různým rozlišením a jinou orientací je v podstatě problémem registrace obrazových dat. Zde je cílem prolnout dva snímky do jednoho. Tento cíl je možné přeformulovat jako hledání vhodné transformace, která zajistí, že obrazy A a B budou po transformaci jednoho z nich totožné. Tedy bude platit:

$$A = Trans.(B)$$

nebo

$$Trans.(A) = B$$

Registraci můžeme využít i v případě, že registrovaný obraz pokrývá pouze část obrazu druhého. Představme si \mathbf{A} a \mathbf{B} jako množiny a pak výše uvedený vztah můžeme přepsat následujícím způsobem:

$$A \subset Trans.(B)$$

nebo

$$B \subset Trans.(A)$$

K získání vhodné transformace mohou vést dvě cesty, cesta přímá a iterativní. Přímé algoritmy registrace obrazových dat, respektive nalezení vhodné transformace, pracují na předpokladu, že máme dvojici bodů vzájemně si odpovídajících na každém z obrázků, jejichž fúzi se snažíme provést. V tomto případě je možné nalézt transformaci pomocí řešení soustavy lineárních rovnic a celý proces může fungovat jednokrokově. Pokud ovšem není možné přesně určit výše zmíněnou dvojici bodů na každých dvou obrazech, které chceme prolnout, je vhodnější iterativní přístup. Ten se v několika krocích snaží transformaci určenou jako počáteční modifikovat tak, aby došlo k co nejlepšímu spojení obrazů.

Abychom dokázali určit, která transformace je "lepší", je třeba najít veličinu, na níž budeme kvalitu prolnutí obrazových dat určovat. Jinými slovy hledáme funkci \hat{T} :

$$\hat{T} = \arg \min_{T \in H} \mathbf{K}(I_1(x, y, z), \mathbf{g}(I_2(\mathbf{T}(x, y, z)))) \quad (7.1)$$

kde \mathbf{K} je kritériální funkcí určující míru podobnosti transformovaných obrazů. \mathbf{T} je množina funkcí, které pro trojrozměrný obraz zobrazují $\mathbb{R}^3 \rightarrow \mathbb{R}^3$. \mathbf{g} je $\mathbb{R} \rightarrow \mathbb{R}$ - interpolační funkce. Funkce \hat{T} necht' je potom hledanou transformační funkcí.

7.1 Rigid / Non-Rigid body registrace

Problém registrace obrazových dat je tedy proložení dvou rozdílných vstupních obrazů do jednoho a tím i nalezení vhodné transformace. Nalezení zmíněné vhodné transformace je možné mnoha způsoby [7–10], jejich klasifikace je shrnuta v článku [6] J. B. Antoine Maintze a Maxe A. Viergever. Klasifikace obrazových metod je možná například dle počtu dimenzí, způsobu porřízení obrazová dat, objektu zkoumání atp. Nejobecnějším dělením je pak dělení dle typu transformace na tzv. Rigid body a Non-Rigid body registraci.

7.1.1 Rigid body registrace

Jak název napovídá (z překladu anglického *rigid* = *pevný, tuhý, neohebný*), jedná se o transformace, které vlastní prostor obrazu nijak nedeformují a zachovávají jeho tvar pevný a neměnný. Jinými slovy tento způsob registrace využívá při transformaci pouze lineárních globálních transformací, jako je rotace a translace.

Nespornou a hlavní výhodou tohoto přístupu je nízký počet stupňů volnosti. Například uvažujeme-li prostor \mathbb{R}^2 , můžeme z možných transformací uvažovat jen translace ve směru x a y a rotaci. S každým dalším rozměrem samozřejmě počet možných transformací narůstá. Pro \mathbb{R}^3 už je translace ve třech směrech x, y, z a rotace kolem těchto tří os. Pro \mathbb{R}^3 máme tedy šest stupňů volnosti, přesto stále neuvažujeme žádnou deformaci obrazu, která by počet možných transformací výrazně navýšila.




Fig. 7.1: Rigid-body transformace

Zdroj: <http://textsandterms.com/glossaries/mechanical/terms/translation.html>

7.1.2 Non-Rigid body

Oproti výše zmíněné Rigid body registraci uvažuje non-rigid body kromě globálních lineárních transformací navíc lokální transformace a také nelineární transformace. Tato skutečnost znamená, že obraz není uvažován jako pevný objekt, ale dochází k jeho deformaci.



Fig. 7.2: Non-Rigid-body transformace

Zdroj: https://www.researchgate.net/figure/Schematic-showing-rigid-and-non-rigid-registration_fig1_8055471

7.1.3 Afinní transformace

Ačkoliv se afinní transformace často řadí mezi Rigid body transformace, uvažuje kromě translačních a rotačních pohybů ještě zkosení a také změnu měřítka. Tento typ transformace respektuje rovnoběžnost a také poměr velikostí jednotlivých úseček.




Fig. 7.3: Afinní transformace

Zdroj: *GEOMETRICKÉ TRANSFORMACE V GIS*
(<http://old.gis.zcu.cz/studium/ugi/referaty/05/GeometrickeTransformace/index.html>)

7.1.4 Výhody a nevýhody jednotlivých přístupů a jejich souvislost se snímáním pacienta

Výhoda Rigid body transformace již byla naznačena výše, a to především malý počet stupňů volnosti. To vede k jednoduchému řešení případného problému. V lékařských zobrazovacích metodách se dá použít v případech, kdy se neočekává změna tvaru zkoumaného objektu. Například dochází-li ke snímání kostí uspaného pacienta, dá se předpokládat, že pokud pacient nezmění polohu, bude se při registraci obrazových dat postačovat Rigid body transformace.

Naopak non-rigid body transformaci použijeme při snímání plic. Předpokládejme, že pacient dýchá a tím pádem i v relativně krátkém

časovém okamžiku plíce mění svůj tvar. Stejně to bude například i pro srdce, které bije. Toto platí především u snímkování pacienta, které trvá delší dobu než několik vteřin.

Rozumným kompromisem se tedy zdá být afinní transformace, která je v oblasti zpracování obrazu pravděpodobně nejvíce využívaným přístupem. Její zápis je podobně jednoduchý jako zápis lineárních transformací Rigid body transformace, ale narozdíl od ní nabízí mnohem širší možnosti díky využití zkosení a změny měřítka.

Tématem této práce je segmentace cévního stromu v játrech, které ani při dýchání nemění svůj tvar. Návrh vlastní metody dokáže, že v takovém případě je možné použití všech výše zmíněných metod. Dalším kritériem pro výběr metody registrace je také doba běhu registračního algoritmu. Pro afinní a non-rigid body transformaci je čas běhu algoritmu výrazně kratší než u non-rigid body transformace (viz tabulka 8.1).

7.2 Metody registrace obrazových dat

Metod pro registraci obrazových dat je celá řada, všechny ovšem mají několik základních kroků, kterými jsou:

1. Detekce vlastností - tento krok zajišťuje nalezení významných objektů a vlastností registrovaných obrazů jako, jsou například hrany, rohy nebo uzavřené hraniční oblasti.
2. Porovnání vlastností - dále je samozřejmě nutné porovnat významné vlastnosti všech registrovaných obrazových dat a najít nejlepší shodu. Důležité pro tento bod je také stanovit metriku, přes kterou budeme hodnotit shodnost vlastností získaných v kroku 1). Cílem je ideálně ke každému významnému objektu obrazu A najít korespondující vlastnost, bod nebo objekt v obrazu B.
3. Definice transformace - hledáme mapovací funkci, která má za cíl registrovaný obraz transformovat tak, aby se co nejlépe překrýval s obrazem referenčním. Může se jednat o rotaci, translaci, zkosení, změnu měřítka a mnoho dalších transformací.
4. Vlastní transformace obrazu a převzorkování - v tomto závěrečném kroku je registrovaný obraz transformován aplikací mapovací funkce, interpolován a následně dojde k vlastnímu proložení obrazů.

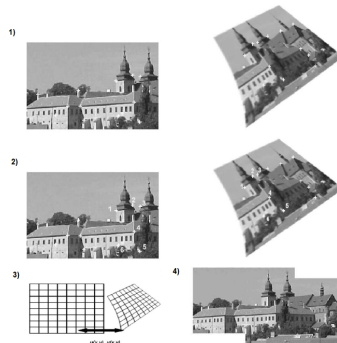


Fig. 7.4: Obecné schéma registrace obrazových dat. 1) detekce významných bodů; 2) jejich porovnání a nalezení odpovídajících bodů v registrovaných obrazech; 3) nalezení mapovací funkce; 4) aplikace transformace a proložení
Zdroj: *Image Registration methods: a survey* Barbara Zitova, Jan Flusser

7.2.1 Bodová registrace

Bodová registrace využívá přesně určených korespondujících bodů nalezení mapovací funkce. Nezbytné je nalezení odpovídajících si bodů ve všech registrovaných obrazech. Hledá se taková transformace (mapovací funkce), která minimalizuje vzdálenost těchto bodů.

V praxi je možné bodovou registraci realizovat umístěním referenčním značek před zahájením snímání obrazu. Bohužel při snímání CT snímků takové umístění značek možné není. Je tedy nutné významné body najít buď automaticky nebo je nechat ručně zadat vyšetřujícího lékaře. Nalezení korespondujících bodů ovšem vyžaduje naprostou přesnost při určování souřadnic, což například při ručním zadání může být významným problémem. Mějme tedy dva obrazy A a B a dva body $(x, y) \in A$ a $(j, k) \in B$. Cílem bodové registrace pak bude najít takovou transformaci, aby bodová chyba $E_{\text{bodová}}$

$$E_{\text{bodová}} = \sum_1^n \|(x_i, y_i) - T(j_i, k_i)\| \quad (7.2)$$

byla co nejmenší. Máme-li dva registrované dvojrozměrné obrazy a uvažujeme-li Rigid body registraci postačí nám pro nalezení mapovací funkce vzhledem ke třem stupňům volnosti pouze tři určené korespondující body, obecně ale platí, že čím více korespondujících bodů v obraze nalezneme, tím přesnější registrace bude.

Významných bodů, které jsou v obrazech detekovány, může být navzdory předchozí úvaze příliš velké množství, čímž stoupá časová náročnost výpočtu. Nutností pro metody bodové registrace je tedy nalezení “rozumného” počtu bodů tak, aby byla chyba pokud možno co nejmenší a na druhou stranu příliš nevzrostla výpočetní náročnost.

7.2.2 Registrace ploch

Další možností, jak registrovat obrazová data je porovnávat plochy nebo hranice. V tomto případě není nezbytné určovat jednotlivé body naprosto přesně. Nevýhodou ale mohou být souměrné objekty. Pokud totiž registrovaný snímek je souměrný, nalezení mapovací funkce není jednoznačné.

7.2.3 Registrace na základě podobnosti voxelů

7.2.3.1 Křížová korelace

Výhodou křížové korelace je její jednoduchá implementace a nezávislost na rozdílné jasové intenzitě referenčního a registrovaného obrazu. Často se také používá tzv. Normalized cross correlation (NCC). Může sloužit například jako metrika shodnosti nebo rozdílnosti dvou obrazů. Její hlavní výhodou oproti standardní křížové korelaci je nižší citlivost na změny amplitudy jasových hodnot obrazových bodů, a tím pádem menší závislost na osvětlení obou snímků. Standardní spojitá křížová korelace φ_{xy} je pro dvě funkce definována následující rovnicí:

$$\varphi_{xy}(t) = \int_{-\infty}^{\infty} x(\tau - t)y(\tau)d\tau \quad (7.3)$$

Křížovou korelaci je také možné normalizovat a obecně ji lze použít pro libovolný počet dimenzí. Pro jednodimenzionální prostor lze její diskrétní tvar zapsat také následujícím způsobem:

$$r_d = \frac{\sum_i [(x[i] - \bar{x}) \cdot (y[i - d] - \bar{y})]}{\sqrt{\sum_i [(x[i] - \bar{x})^2]} \sqrt{\sum_i [(y[i - d] - \bar{y})^2]}} \quad (7.4)$$

Tato rovnice normalizuje výsledky křížové korelace na $r_d = \pm 1$. Transformace registrovaného obrazu je pak určena dle globálního maxima hodnot získaných křížovou korelací. Typický výsledek s jasným globálním maximem je naznačen na následujícím grafu:




Fig. 7.5: Výsledek křížové korelace

Křížová korelace zmíněná v předchozím případě má výpočetní náročnost $O(N^2)$. Za účelem zrychlení je možné využít rychlou Fourierovu transformaci

(FFT). Vycházejme z korelačního teorému, který říká, že vynásobíme-li Fourierovu transformaci jedné funkce komplexním konjugátem (z angl. complex conjugate) Fourierovy transformace druhé funkce, dostaneme Fourierovu transformaci jejich korelace. Tím se z časové oblasti dostaneme do frekvenční oblasti a výsledky dostaneme stejné.

Pro zajímavost uvádíme v následující tabulce porovnání korelace bez a s použitím FFT:

Velikost polí	Použito FFT	Čas výpočtu/s
512	NE	0,006
512	ANO	0,002
768	NE	0,013
768	ANO	0,003
1024	NE	0,025
1024	ANO	0,020

Tab. 7.1: Porovnání korelace s a bez použití FFT

7.2.3.2 Minimalizace variace poměrů intenzit

Tato metoda je použitelná pouze pro monomodální obrazovou registraci. Vychází z předpokladu, že hodnota každého pixelu (voxelu) může být porovnána s odpovídajícím obrazovým bodem druhého obrazu na základě jediného faktoru. Algoritmus je pak tvořen třemi jednoduchými kroky. V prvním kroce jsou hodnoty $R(i)$ spočteny jako poměr hodnoty referenčního pixelu (voxelu) $I_R(i)$ a zkoumaného pixelu (voxelu) $I_S(i)$. Tedy:

$$R(i) = I_R(i)/I_S(i) \quad (7.5)$$

Druhý krok je potom výpočtem standardní odchylky:

$$\sigma_R = 1/N \sum_i (R(i) - \Delta R(i)) \quad (7.6)$$

kde N je počet pixelů. Ve třetím kroku algoritmu je provedena registrace na základě minimalizace normalizované odchylky

$$\sigma_{norm} = \frac{\sigma_R}{\Delta R} \quad (7.7)$$

7.2.4 Registrace na základě informace

Registraci obrazových dat je možné také provádět na základě množství sdílené informace. Předpokládejme tedy opět dva obrazy, pokud jeden z nich je možné přímo umístit do obrazu jiného, ponese pak celkový registrovaný obraz přesně tolik informace jako první z obrazů. Budou-li se registrované obrazy překrývat částečně, pak překrývaná část bude sdílená informace a celkovou informaci pak bude možné zapsat následujícím způsobem: $A + SDÍLENÁ + B$

(A i B rozumějmě informace obou obrazů bez sdílené informace). Úkol registrace je tedy možné pojmut jako úlohu maximalizace informace sdílené nebo naopak jako minimalizaci informace celkové.

7.2.4.1 Entropie

Entropie je míra neurčitosti určitého jevu. Pokud pracujeme s informací, je tuto veličinu klíčové zavést. Definována byla Josiah Willard Gibbs jakožto:

$$S = -k \sum_i P_i \ln P_i \quad (7.8)$$

kde S je počítaná entropie, P_i pravděpodobnost, že nastane stav i . Podle Gibbse, který entropii definoval pro termodynamické stavy, je k Boltzmannova konstanta $1,38066 \cdot 10^{-23} JK^{-1}$. Jednotka entropie je pak stejná jako jednotka tepelné kapacity. My ovšem zavedme $k = 1/\ln(2)$, což platí pro entropii v bitech a odtud dostáváme obecně používaný tvar entropie a to:

$$S = \sum_i P_i \log_2 P_i \quad (7.9)$$

Entropie je maximální, pokud je pravděpodobnost všech jevů stejná. Minima dosáhneme, pokud množina všech jevů obsahuje jev jistý, tedy jev s pravděpodobností rovno jedné. Je snadné dopočítat, že entropie je nulová. V případě informačního přístupu k registraci obrazu je nutné si také uvědomit, že celková entropie se mění, pokud budou obrazy vůči sobě pootočené a pokud tedy dojde k interpolaci.

7.2.4.2 Minimalizace celkové informace

Jak již bylo zmíněno výše, je registraci obrazových dat možné brát jako úlohu maximalizace sdílené informace nebo naopak minimalizace informace celkové. Věnujme se nyní druhému případu, tedy minimalizaci celkové informace. Mějme opět dva intenzitní obrazy A, B a transformace $T(B)$ aplikovanou na druhý z obrazů. Tyto obrazy proložme jeden druhýma a spočtěme pravděpodobnosti $p_{i,j} = p(A(x_k) = i \cap T(B(x_k)))$. X_k jsou souřadnice právě zkoumaného obrazového bodu a i, j jsou hodnoty intenzity zkoumaných obrazových bodů transformovaného obrazu B a netransformovaného obrazu A . Společná entropie je tedy:

$$S(A, T(B)) = \sum_i \sum_j p_{i,j} \cdot \log_2(p_{i,j}(A, T(B))) \quad (7.10)$$

Pokud jsou obrazy zcela totožné, bude platit, že celková informace je rovna informaci jednoho z obrazů. Naopak neponesou-li oba obrazy žádnou společnou informaci, jejich celková entropie bude součtem $S(A, T(B)) = S(A) + S(T(B))$. Z čehož plyne, že pro obecné dva obrazy platí:

$$S(A, T(B)) \leq S(A) + S(T(B)) \quad (7.11)$$

Jak již bylo zmíněno v úvodu této kapitoly, dochází-li při transformaci k rotaci a následné interpolaci, dostáváme $S(T(B)) > S(B)$. To může být problém, protože celková informace a potažmo i entropie roste, i přesto, že obraz je správně umístěn.

7.2.4.3 Společná informace

V angličtině se setkáváme s pojmem *mutual information* (MI) [14–16], který je často využíván i v české literatuře, dále tedy budeme využívat anglickou variantu názvu této metriky pro registraci obrazových dat. MI je druhým možným přístupem k registraci pomocí informace a odstraňuje také problém popsáný výše, tedy fakt, že při interpolaci po provedení rotace registrovaného obrazu dojde k navýšení celkové informace, ačkoliv by (pokud je obraz správně umístěn) měla celková informace klesat. Myšlenka MI je měřit rozdíl mezi součtem informací jednotlivých obrazů a obrazu celkového (vzniklého výsledkem registrace). Platí tedy:

$$S^{MI}(A, T(B)) = S(A) + S(T(B)) - S(A, T(B)) \quad (7.12)$$

po dosažení dostáváme:

$$S^{MI}(A, T(B)) = \sum_i \sum_j p_{i,j}(A, T(B)) \cdot \log_2 \frac{p_{i,j}(A, T(B))}{p_i(A)p_j(T(B))} \quad (7.13)$$

Tento vzorec je ovšem spolehlivý pouze pokud celková informace $S(A, T(B))$ roste nepatrně. Pokud ovšem máme zašuměný obraz, který má navíc nízkou intenzitu obrazových bodů, může dojít ke zkreslení výsledků.

Za účelem odstranění této skutečnosti můžeme zavést normalizovanou MI.

$$S_{NORM}^{MI}(A, T(B)) = \frac{S(A) + S(T(B))}{S(A, T(B))} \quad (7.14)$$


V tomto případě je MI poměrem součtu informací obou obrazů a celkové informace. Vzhledem k tomu, že tento přístup vyjadřuje informaci, nakolik je jeden obrázek obsažen v druhém, při registraci se budeme snažit o maximalizaci MI.

7.2.5 B-Spline registrace

B-Spline (také basis spline) registrace je non-rigid body registrace reprezentovaná lineární kombinací bázevých funkcí:

$$v(x) = \sum_i p_i \beta_i(x) \quad (7.15)$$

Kde β je po částech kubický polynom, p je měřítko.

Fig. 7.6: B-Spline a) β b) p c) $v(x)$

Zdroj: <http://chapter.aapm.org/NE/DOCUMENTS/Presentations/2011Winter/sharp-neaapm-2011-02-10.pdf>

Základní myšlenkou deformačního modelu této metody je posun bodů na povrchu deformovaného objektu. Oblast trojrozměrného obrazu definujeme:

$$\Sigma = \{(x, y, z) | 0 \leq x \leq X, 0 \leq y \leq Y, 0 \leq z \leq Z\} \quad (7.16)$$

Nyní definujeme síť kontrolních bodů Ψ s rozměry n_x, n_y, n_z . Pro body $\Psi_{i,j,k}$ můžeme zapsat:

$$T_{nonrigid}(x, y, z) = \sum_{i=0}^3 \sum_{m=0}^3 \sum_{n=0}^3 B_i(u) B_m(v) B_n(w) \Psi_{i,m,n} \quad (7.17)$$

kde $B_x, x \in (i, j, k)$ jsou bázové funkce a Ψ reprezentuje deformační mřížku. Pro registraci obrazových dat v lékařství se nejčastěji používá jako řídicí oblast osmiokolí bodu. Vzdálenosti jsou pak definovány následovně:

$$\Omega_x = \left[\frac{x}{N_x} \right] - 1, \Omega_y = \left[\frac{y}{N_y} \right] - 1, \Omega_z = \left[\frac{z}{N_z} \right] - 1 \quad (7.18)$$

kde N je počet voxelů pro osy x, y a z . Posun každého voxelu v okolí $\Omega(x, y, z)$ je ovlivněn zhruba 64 kontrolními body. Souřadnice 64 kontrolních bodů $CP(l, m, n)$ vypočteme následujícím způsobem:

$$CP_l = \left[\frac{x}{N_x} - 1 + i \right], CP_m = \left[\frac{y}{N_y} - 1 + j \right], CP_n = \left[\frac{z}{N_z} - 1 + k \right] \quad (7.19)$$

Jednotlivé lokální souřadnice $Local(u, v, w)$ v oblasti $\Omega(x, y, z)$ a hodnota jsou normalizována do intervalu $[0, 1]$. Poté je možné zapsat:

$$Local_u = \frac{x}{N_x} - \left[\frac{x}{N_x} \right], Local_v = \frac{y}{N_y} - \left[\frac{y}{N_y} \right], Local_w = \frac{z}{N_z} - \left[\frac{z}{N_z} \right] \quad (7.20)$$

7.2.6 Non-image based registration

V českém překladu *neobrazová registrace*. Zůstaňme raději u anglického označení. Tato metoda vyžaduje aby byly obrazy snímány téměř ve stejný čas na stejném místě. Pokud uvažujeme tento požadavek v medicínském prostředí, vyžadujeme naprostou nehybnost pacienta. Využití je například v kombinaci CT nebo MRI a ultrazvukového snímání. Myšlenka je taková, že jsou kalibrovány souřadné systémy obou snímků a k vlastní registraci není třeba využívat přímo obrazových dat. Tato technika se v praxi používá například pro záznam polohy chirurgických nástrojů užívaných operačním robotem na jeho rameno. Tyto specifické požadavky definují úzkou oblast použití této metody.

7.3 Optimalizátor

Důležitým faktorem pro registraci obrazových dat je volba vhodného optimalizátoru. Tím může být například [11,12]:

1. Exhaustive - tento optimalizátor vychází z tzv. exhaustive search (exhaustivního vyhledávání) v diskretní mřížce definované v parametrickém prostoru. Typickým využitím je vykreslení metriky prostoru k získání informace o tom, kolik šumu obsahuje.
2. Powell - tento optimalizátor využívá Brent line search algoritmus. Brentova metoda kombinuje bisekční metodu, secantovou metodu a inverzní kvadratickou interpolaci. Algoritmus se snaží použít potenciálně rychle konvergující secantovou metodu nebo inverzní kvadratickou interpolaci, pokud je to možné, ale v případě potřeby se vrátí zpět k robustnější bisekční metodě.¹⁵
3. Gradient descent - aktuální pozice se vypočítává následujícím způsobem: $p_{n+1} = o_n + LearningRate \frac{\partial f(p_n)}{\partial p_n}$, kde *LearningRate* je hlavním parametrem tohoto optimalizátoru.
4. L-BFGS-B (Limited memory Broyden, Fletcher, Goldfarb, Shannon, Bound Constrained) - tento algoritmus minimalizuje nelineární diferencovatelnou funkci $f(x)$ kde x je vektor n reálných proměnných. Patří mezi tzv. *quasi-Newtonovské metody* a hlavní výhody přináší při aplikacích s omezenou výpočetní pamětí. Metoda L-BFGS-B využívá odhad inverzní Hessiánovy matice k vyhledání nové hodnoty proměnné v prostoru.

7.4 Interpolace

Při transformaci obrazu dochází často k následujícímu problému: Mějme obraz \mathbf{A} a celočíselný souřadnicový systém. Na zmíněný obraz použijeme transformaci s použitím rotace, translace a dalších možných změn. Jelikož tato transformace je obecná, mohou vznikat, a často také vznikají, reálné souřadnice. Pro rekonstrukci obrazu je ovšem nezbytné zobrazit výsledek v celočíselném souřadném systému. Právě za tímto účelem je použita interpolace výsledku, která s využitím hodnot jednotlivých pixelů v 2D obrazu, voxelů v 3D obraze převádí reálné souřadnice do celočíselné mřížky.

7.4.1 Metoda nejbližšího souseda

Jinak se tato metoda také nazývá "interpolace 0-tého řádu". Její největší devízou je rychlost. Princip je velmi jednoduchý - zkoumaný pixel získává hodnotu svého nejbližšího souseda. V praxi se často používá varianta

¹⁵ Metodu představil australský matematik Richard Pierce Brand ★ 20. dubna 1946 a staví na algoritmu holandského matematika Theodoruse Jozefa Dekkera ★ 1. března 1927

zaokrouhlování souřadnic. Hlavní nevýhodou je nepřesnost, ovšem na druhou stranu je metoda použitelná pro všechny typy obrazů. Jak již bylo zmíněno, je velmi rychlá a je jí možné použít pro indexované a černobílé obrazy. Matematicky jí můžeme pro 2D obraz zapsat takto:

$$f(x, y) = \left\{ \begin{array}{l} p(i, j) \text{ pro } i - \frac{1}{2} < x \leq i + \frac{1}{2}, j - \frac{1}{2} < y \leq j + \frac{1}{2} \\ p(i, j + 1) \text{ pro } i - \frac{1}{2} < x \leq i + \frac{1}{2}, j - \frac{1}{2} < y \leq j + \frac{3}{2} \\ p(i + 1, j) \text{ pro } i - \frac{1}{2} < x \leq i + \frac{3}{2}, j - \frac{1}{2} < y \leq j + \frac{1}{2} \\ p(i + 1, j + 1) \text{ pro } i - \frac{1}{2} < x \leq i + \frac{3}{2}, j - \frac{1}{2} < y \leq j + \frac{3}{2} \end{array} \right\} \quad (7.21)$$

kde (i, j) jsou body v prostoru s celočíselnými souřadnicemi, $p(i, j)$ hodnota pixelu na příslušných souřadnicích $(x, y) \in \mathbb{R}^2$.

7.4.2 Bilineární interpolace

Tato interpolace využívá nikoliv jednoho, jako předchozí metoda, ale čtyři nejbližší pixely, z nichž počítá vážený průměr. Interpolovanému pixelu je pak přiřazena hodnota váženého průměru.

$$f(x, y) = (y - j)[(i + 1 - x)p(i, j + 1) + (x - i)p(i + 1, j + 1)] + (j + 1 - y)[(i + 1 - x)p(i, j) + (x - i)p(i + 1, j)] \quad (7.22)$$

Princip bilineární interpolace je znázorněn i na následujících schématech:




Fig. 7.7: Bilineární interpolace

Zdroj: https://cs.wikipedia.org/wiki/Bilineární_interpolace

7.4.3 Bikubická interpolace

Bikubická interpolace je dalším rozšířením na dvourozměrnou pravidelnou mřížku. K jejímu výpočtu se využívá například Lagrangeových polynomů, kubického splinu nebo kubické konvoluce.

$$f(x, y) = \sum_{i,j=0}^3 c_i(x)c_j(y)f_{ij} \quad (7.23)$$

Kde $c_i(x)$ a $c_j(y)$ jsou kubické polynomy a f_{ij} hodnota na jednotlivých pozicích tak jak je naznačeno na levém schématu z následujících dvou, které ukazují princip Bikubické interpolace.




Fig. 7.8: Bikubická interpolace

Zdroj: http://www.fotoroman.cz/glossary/3_interpolace.htm

7.4.4 Spline interpolace

Interpolační spline spočívá v tom, že kromě průchodu všemi uzlovými body $f(x, y)$ má také spojitou alespoň první derivaci. Pro jednorozměrný prostor poté pro $\forall(x_i)$ platí:

$$\lim_{x \rightarrow x_{i-}} f'(x) = \lim_{x \rightarrow x_{i+}} f'(x) \quad (7.24)$$

8. NÁVRH METODY PRO NALEZENÍ CEVNÍHO STROMU V CT SNÍMCÍCH

Hlavním cílem této práce je nalezení cévních stromů v játrech z 3D zobrazovacích metod v medicíně, jako je například výpočetní tomografie. Proto abychom získali co nejpřesnější segmentaci cévního stromu je vhodné použít několik snímků, respektive několik sad snímků. Při snímání pacienta pod CT je často do cévního řečiště zavedena kontrastní látka a pacient je snímán v krátkém čase vícekrát. Na první sadě snímků pak můžeme vidět výrazněji cévy, kde krev do jater přitéká, a na druhé sérii snímků pořízené s časovým odstupem je pak možné vidět výrazněji cévy, které krev s kontrastní látkou odvádějí. Důvodů pro použití několika sérií snímků může být několik, ale obecně se jedná o skutečnost, že každá série nese část informace, která je v druhé sérii nedostupná, zašuměná nebo neúplná.

8.1 Registrace

Nejprve je tedy nezbytné obě série obrazových snímků na sebe vzájemně registrovat. V prvním kroku navržené metody je registrace provedena nad celou sérií snímků dle následujícího schématu:

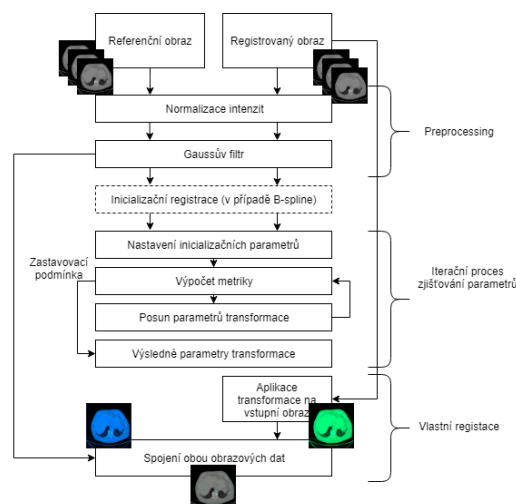


Fig. 8.1: Schéma registrace

Transformační metoda	Počet iterací	Výsledná hodnota MI	Doba běhu/s
Eulorova 3D transformace	9	-0,341	18,74
Afinní transformace	9	-2,2510	33,91
B-Spline registrace	20	-2,366	11 931,56

Tab. 8.1: Porovnání registračních metod

Pozn.: Počet iterací metody B-Spline byl omezen na 20 z důvodu dlouhého času běhu algoritmu. Zbylé dvě metody byly zastaveny podmínkou minimální kovergence - ustálily se dříve, než dosáhly maximálního počtu iterací.

Pro registraci několika sérií byly použity tři metody: Non-rigid body realizované 3D Eulerovou (translace a rotace) transformací, Affinní transformace a B-Spline registrace. Pro implementaci byl použit Python a balíky ITK (Insight Toolkit), potažmo Simple ITK, který nástroj ITK využívá. Metrika zvolená pro tuto úlohu je Mutual information:

Optimalizérem byl zvolen Gradient descent. První série má 155x512x512 voxelů a série č. 2 78x512x512 voxelů. Na následující sérii snímků jsou vidět vstupní obrazy a výsledek registrace. Na první pohled jsou si obě série, respektive náhodně vybraný zástupce (jeden řez) série, velmi podobné (jedná se ostatně o stejného pacienta), ale při detailním pohledu se liší. Obrázky c) a d) ukazují výsledek registrace, přičemž odstíny šedé reprezentují komponovanou část obrazu, která si odpovídá v obou snímcích (po rozmazání, nikoliv na úrovni detailu, který bude následně použit pro segmentaci cévních stromů).




Fig. 8.2: Registrace obrazových dat (CT) - dva snímky jednoho pacienta: a) ukázka jednoho řezu série; b) ukázka dpovídajícího řezu druhé série; c) výsledek registrace s použitím Rigid-body transformace (tóny šedé = informace získaná kombinací obou zdrojových sérií; zelená=referenční obraz (série a)); červená = registrovaný obraz (série b)); d) výsledek registrace s použitím Afinní transformace; e) B-Spline

První krok registrace slouží k odstranění rozdílů v natočení pacienta, drobném pohybu ke kterému může dojít mezi pořízením jednotlivých sérií, rozdíly mezi nádechem a výdechem atp. Aby byly lépe vidět rozdíly při použití jednotlivých metod, je na další sérii zobrazen detail části řezu registrovaných sérií.




Fig. 8.3: Detail výsledků registrace obrazových dat - a) Rigid-body transformace; b) Afinní transformace; c) B-Spline

8.2 Segmentace jater v jednotlivých sériích

K segmentaci jater v jednotlivých sériích byla použita *lisa* [17] (LIver Surgery Analyser). Jedná se o software vyvinutý na Západočeské univerzitě, který slouží pro analýzu medicínských obrazových dat. Segmentace se pomocí *lisy* provádí semi-automaticky. Uživatel vybírá seedy (body v obraze) reprezentující segmentovanou část a body reprezentující pozadí. Vlastní segmentace pak probíhá pomocí metody Graph-cut [18].




Fig. 8.4: Ukázka segmentace v programu LISA

Pomocí tohoto programu byla vytvořena tzv. maska, kterou je možné aplikovat na 3D snímek získaný ze snímané série, a tím omezit segmentaci cévního stromu jen na játra. Tím se segmentovaný obraz zmenší, v tomto případě na 46x250x274. Použité metody pro segmentaci cévního stromu jsou velmi citlivé na nastavení parametrů (velikost jader filtrů, rozsahy intenzit, rozdíl mezi intenzitou hledaných cév a zbytku orgánu). Obecné nastavení parametrů segmentace je velmi složité a vzhledem k tomu, že 3D obrazy celého těla jsou násobně větší, roste i časová náročnost provádění navrženého algoritmu.

8.3 Segmentace cévního stromu

Segmentace cévního stromu je velmi citlivá na kvalitu obrazu vstupních obrazů a proto je potřeba provést preprocessing dat před aplikací vlastních segmentačních algoritmů. Jedná se několikanásobou aplikaci různých filtrů (Gaussův, bilaterální, mediánový), metody adaptive histogram equalization. Segmentační proces je znázorněn na následujícím schématu:

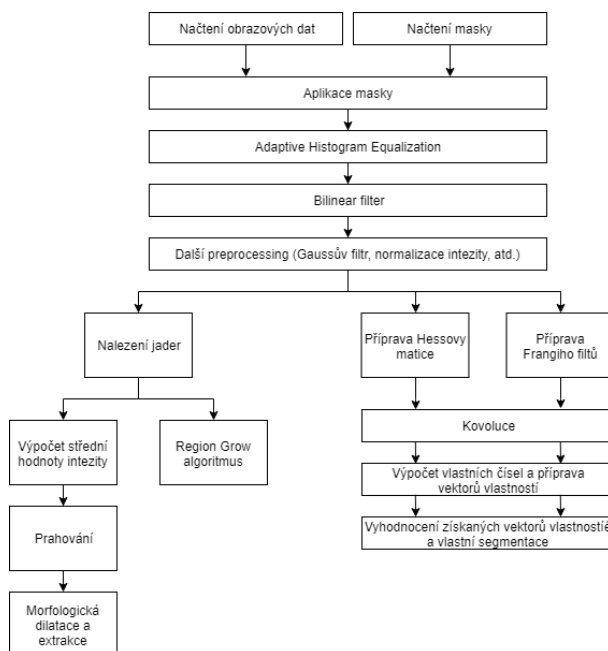


Fig. 8.5: Schéma segmentace

8.3.1 Nalezení významných regionů

Pro snímky jsou nejprve nalezeny významné body. Tento krok využívá myšlenky, že průřez cévou je buď kruh nebo elipsa. Pro nalezení takových struktur je použit následující algoritmus:

1. Prahování - zdrojový obraz je převeden pomocí prahování na několik binárních obrazů. Proces probíhá v několika krocích, přičemž práh v každém kroku je definovaný jako práh v kroku předchozím + definovaná hodnota.
2. Seskupení - V každém binárním obraze jsou spojené pixely s hodnotou 1 do celistvého regionu (blobu).
3. Sloučení - středy binárních blobů v binárních obrazech jsou vypočteny a bloby, jejichž středy jsou vzdálené blíže než definovaná vzdálenost, jsou sloučeny.
4. Výpočet vlastností - pro každý blob je vypočten střed, velikost, konvexita, konkávnost a poměr momentů.

Díky poslednímu bodu je možné filtrovat nalezené bloby dle jejich vlastností. Předpokládejme, že cévy, respektive jejich průřez, bude mít přibližně kruhový charakter a obsah v mezích, které je možné definovat. Pokud máme například obraz 250x250, předpokládejme, že průřezy větších cév budou mít obsah mezi

25 a 300 pixely. Větší útvary pak mohou reprezentovat například celá jatra nebo kruhu podobnou část se stejnou intenzitou.

8.3.2 Segmentace pomocí prahování

První a nejjednodušší metoda je segmentace prahováním. Nejprve jsou nalezeny významné body, pro které je spočtena průměrná hodnota intenzit. Pro tuto metodu je nezbytné určit rozsah, respktive toleranci intenzity jasu. Pomocí této hodnoty určíme minimální a maximální hodnoty intezity jasu. Jako cévy jsou označeny body, které jsou v rozsahu daných intenzit. Tato metoda je skutečně naivní a v obraze obsahujícím šum, jakým reálná data jsou, dojde k označení mnoha bodů, které mají podobnou intezitu jako cévy a do cévního stromu nepatří.

8.3.3 Segmentace pomocí metody narůstání oblastí

Podobně jako předchozí metoda, využívá segmentace pomocí růstu oblastí (region grow) významné body. Těmi jsou v tomto případě středy významných regionů. Růst regionů opět pracuje s tolerancí intezity, přičemž každý sousední bod je přidán do regionu, pokud rozdíl intenzity těchto sousedních bodů není větší než definovaná tolerance.

8.3.4 Segmentace založená na analýze vlastních čísel Hessovy matice

Další dvě metody využívají vektory vlastností reprezentující každý jednotlivý voxel (použití Hessovy matice a Frangiho filtrů je popsáno v kapitole 6.5.1), získané konvolucí s Hessovou maticí, případně Frangiho filtrem. Na základě analýzy vlastních čísel vypočtené matice vlastností je možné určit, které body patří do cévního stromu a které nikoliv. Konvoluce s Hessovou maticí je provedena pro několik různých natočení této matice a v několika směrech v rámci trojrozměrného obrazu. Pro získání nejlepších výsledků je možné použít různé velikosti Hessovy matice a různé měřítko vstupního obrazu.

Pozn.: jedna metoda implementuje vlastní analýzu vlastních čísel po aplikaci Frangiho filtru (dále označovaná jako Frangiho filtr). Druhá metoda využívá knihovnu ITK, v níž je implentována metoda Hessian Recursive Gaussian Filter (dále označovaná Implementace Hessianu ITK)

Výsledky segmentace cévních stromů pro reprezentivní obraz je zobrazena pomocí 3D vizualičního nástroje Mayavi níže:

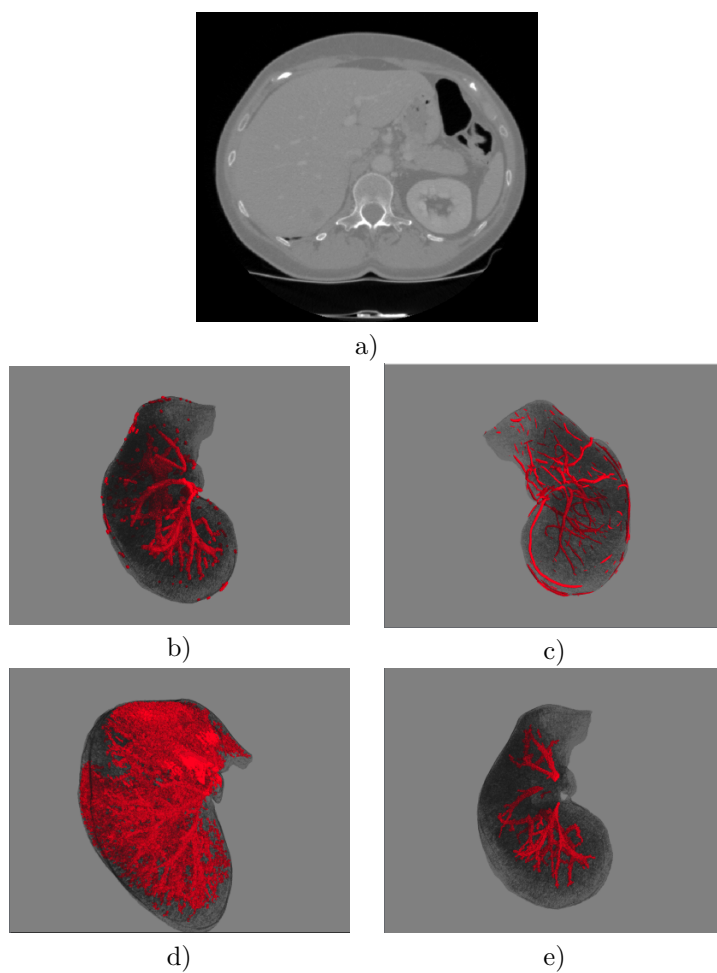


Fig. 8.6: Segmentace cévního stromu jater z různých úhlů za použití různých segmentačních metod pro vzorový příklad a) zdrojový obraz; b) Frangiho filtr; c) Implementace Hessianu ITK; d) prahování střední hodnotou nalezených cév e) Region grow

Pro snímky registrované v předchozím kroku aplikujeme nyní tyto segmentační metody. V některých případech segmentační metody identifikují falešně jako cévy například hrany nebo okraje jater. Pro tyto případy je nutné dodatečné zpracování segmentovaných snímků. Pomocí hranového detektoru a nalezení významných regionů s velkým obsahem voxelů můžeme tyto oblasti identifikovat a následně z obrazu odstranit. Na sérii snímků níže jsou zobrazeny výsledky segmentace pro jednotlivé série reprezentované vždy jedním z řezů binárního obrazu a 3D modelem cév.

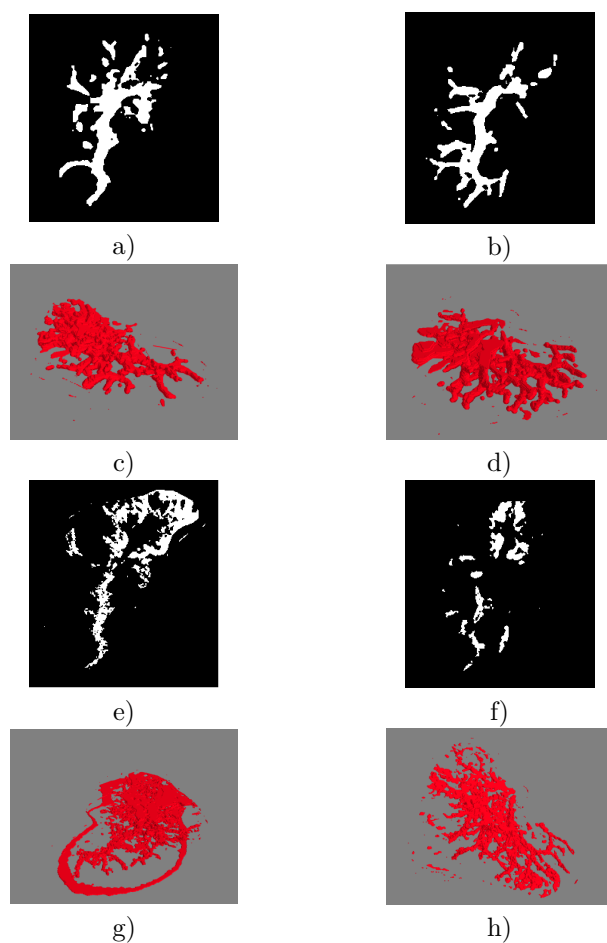


Fig. 8.7: Segmentace cévního stromu pro jednotlivé série registrovaných CT snímků a) Frangiho filtr (série 1); b) Frangiho filtr (série 2); c) 3D vizualizace segmentovaných cév Frangiho filtr (série 1); d) 3D vizualizace segmentovaných cév Frangiho filtr (série 1); e) Region grow (série 1); f) Region grow (série 2); g) 3D vizualizace segmentovaných cév Region grow (série 1); h) 3D vizualizace segmentovaných cév Region grow (série 2)

Pozn.: 2D snímky reprezentují vždy 27. řez série

Následně použijeme znovu některý z registračních algoritmů s jemnější zastavovací podmínkou tak, abychom segmentovaná játra se zvýrazněnými cévními stromy mohli ještě lépe zarovnat. Výsledky kompozice registrovaných jater, potažmo cévních stromů, nám dávají několik informací:

- cévy identifikované v obou vstupních sériích jsou skutečně s velkou pravděpodobností cévami
- kompozicí obou segmentovaných cévních svazků získáme rozšířený cévní strom
- pokud se jedná o případ, kdy pomocí reflexní látky jsou zvýrazněny cévy nejprve při přitékání krve do jater a následující snímky pak naopak s časovým odstupem při odtoku krve z orgánu dostáváme informaci, které cévy patří do zmíněných skupin společně se společnou informací o cévním stromu.




Fig. 8.8: Segmentace cévního stromu registrovaných obrazových snímků (Frangiho filtr) a) ukázka jednoho řezu před použitím registrace; b) ukázka jednoho řezu před použitím registrace (série 2); c) 3D vizualizace segmentovaných cévních stromů po registraci (červená - body nalezené v obou snímcích; modrá - série 1; zelená - série 2); d) kompozice obou sérií




Fig. 8.9: Segmentace cévního stromu registrovaných obrazových snímků (Region Grow) a) ukázka jednoho řezu před použitím registrace; b) ukázka jednoho řezu před použitím registrace (série 2); c) 3D vizualizace segmentovaných cévních stromů po registraci (červená - body nalezené v obou snímcích; modrá - série 1; zelená - série 2); d) kompozice obou sérií

Jedna z možných metrik pro vyhodnocení výsledku je počet nalezených voxelů označených jako cévy. Následující tabulka ukazuje právě tyto počty pro jednotlivé metody samostatně a následně pro sečtení modelů segmentovaných cévních stromů - v tomto případě jsou považovány oba segmentované cévní stromy jako důvěryhodné a voxelu je přiřazena hodnota 1 (patří do cévního stromu), pokud se objevuje alespoň v jedné ze segmentovaných oblastí. Poslední dva řádky porovnávají počet nalezených voxelů v případě kombinace obou sérií. Přičemž oba výsledky počítají s registrací na úrovni celých vstupních sérií, výsledek na posledním řádku pak s dvoukrokovou registrací, přičemž je druhá registrace provedena pouze na úrovni jater.

	Počet voxelů		Počet voxelů
Série 1 - Frangiho filtr	120 846	Série 1 - manuální segmentace	27 190
Série 1 - Region grow	57 886	Série 2 - manuální segmentace	32 851
Série 2 - Frangiho filtr	103 443	Série 1 - Lisa Region grow segmentace	9 387
Série 2 - Region grow	38 018	Série 2 - Lisa Region grow segmentace	12 164
Kombinace obou sérií bez registrace	123 187	Kombinace obou sérií manuální segmentace	55 391
Kombinace obou sérií po registraci	120 846	Kombinace obou sérií (Lisa)	20 582

Tab. 8.2: Porovnání segmentovaných voxelů identifikovaných jako cévy

Počet voxelů indetifikovaných jako cévy ovšem není zcela vhodnou a objektivní metrikou, jelikož se může jednat o chybně určené voxely. Uvažujme nyní, že ručně segmentované cévní stromy jsou správně a vůči nim můžeme porovnat jednotlivé výsledky pro metody Region Grow a Frangiho filtru navržených metod. Je zřejmé, že ani ruční segmentace neodhalí všechny cévy, protože vstupní data nemusí obsahovat kompletní informaci. Navíc musíme uvažovat i lidskou chybu při segmentaci. Nicméně ruční segmentace je v případě nalezení cévního stromu tou nejlepší možnou. Jednou z jejích vlastností je fakt, že neobsahuje chybně identifikované cévy.

Zavedme nyní dvě metriky, s jejichž pomocí můžeme výsledky vyhodnotit, jedná se o obecně používaný *Sørensen–Dice coefficient*¹⁶ a *Jaccard index*. Sørensen–Dice coefficient byl nezávisle na sobě zaveden botanikem Thorvald Sørensenem (1948) a Lee Raymond Dicem (1945). Můžeme jej zapsat jednou z následujících rovnic:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (8.1)$$

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (8.2)$$

Kde X a Y jsou množiny bodů a $X \cap Y$ je průnik obou množin. Ve druhé rovnici TP (true-positive) - je počet správně identifikovaných bodů označených jako cévy, FP (false-positive) - počet nesprávně indetifikovaných bodů, FN - (false-negative) - počet bodů, které nebyly označeny jako cévy, ale měly být (v referenčním obraze jsou označeny jako cévy).

Druhou metrikou je Jaccard index, který můžeme zapsat:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} \quad (8.3)$$

¹⁶ koeficient je známý i pod názvy *F1 score*, *Czekanowski's binary (non-quantitative) index*, *Zijdenbos similarity index*

	Sørensen–Dice coefficient Region Grow	Sørensen–Dice coefficient manuální segmentace	Jaccard index Region Grow	Jaccard index manuální segmentace
Série1 (Frangiho filtr)	0,1013	0,3299	0,0534	0,1976
Série2 (Frangiho filtr)	0,1357	0,3754	0,0728	0,2311
Série1 (Region grow)	0,1383	0,3192	0,0743	0,1899
Série2 (Region grow)	0,2330	0,3682	0,1319	0,2257
Kombinace sérií bez registrace (Frangiho filtr)	0,1047	0,3578	0,0552	0,2179
Kombinace sérií po registraci (Frangiho filtr)	0,1013	0,3299	0,0534	0,1976
Kombinace sérií bez registrace (Region grow)	0,1827	0,4215	0,1005	0,2670
Kombinace sérií po registraci (Region grow)	0,1145	0,3053	0,0607	0,1802

Tab. 8.3: Porovnání segmentovaných voxelů identifikovaných jako cévy

Pro obě použité metriky platí, že naprostá shoda je reprezentována hodnotou 1, naopak pro vůbec žádnou shodu jsou obě metriky nulové. Z výše uvedených výsledků je patrné, že se navržené automatické metody poměrně výrazně liší od ruční segmentace cévního stromu. Velký rozdíl je například v tom, že v některé části jater se nalezené cévy "slily" v jeden velký blok. Dle výsledků 8.3.4 vychází jako nejpodobnější ruční segmentaci metoda Region Grow s využitím dat pouze z první série. Z výsledků vzniklých registrací obou sérií je lepší (podobnější referenční segmentaci) varianta využívající metodu Region Grow a registraci na úrovni celých vstupních sérií.

9. ZÁVĚR

V této práci byly vypracovány metody pro registraci obrazových dat využívající rigid body i non-rigid body registrace. Pokud jsou vstupní data podobná (jedná se například o jednoho pacienta), pak metody rigid-body registrace a afinní transformace vykazují podobné výsledky a zhruba stejný čas výpočtu parametrů transformace. Chceme-li analyzovat například cévní řečiště, jeví se jako vhodnější metoda afinní transformace, která dokáže potlačit změny v časovém rozestupu pořízení snímků. Non-rigid body registrace, v této práci reprezentovaná metodou B-Spline, vykazuje ještě významně lepší potlačení morfologických změn. Ovšem náročnost výpočtu je násobně vyšší než u metod dříve zmíněných. Metody Non-Rigid body registrace je vhodné použít s nějakou formou inicializační transformace (registrace) tak, aby byla zajištěna konvergence ke správnému výsledku. Nevýhodou Non-Rigid body registračních metod je, že pokud se při některé z iterací příliš odchýlí registrovaná část obrazu od odpovídající části referenčního obrazu, může dojít k deformaci transformovaného obrazu a hledání parametrů pak nebude konvergovat ke správnému výsledku.

Pro registrační metody cév je možné využít několik metod založených buď na intenzitě zkoumaných voxelů (Region Grow a prahování) nebo na analýze zkoumání vlastností okolí bodu (konvoluce s Hessovou maticí a Frangiho filtry). Všechny tyto metody jsou velmi citlivé na kvalitu vstupních dat. Pokud se bude jednat o zašuměná data, metody velmi rychle začnou selhávat, a tak je nezbytné obrazová data před aplikací segmentačních metod podrobit důkladnému preprocessingu.

Jednotlivé oblasti, v nichž je prováděna segmentace cévního stromu, je vhodné nejprve segmentovat z celkového obrazu. Důvodem je především fakt, že pro každou část (ve smyslu každý orgán nebo zkoumaná tkáň) je vhodné nastavit parametry segmentačních metod odlišně. Je známá i skutečnost, že i na úrovni jednotlivých orgánů, například jater, mají různé části různou intenzitu obrazových bodů. To způsobuje při segmentačních úlohách chyby a pro zvýšení přesnosti by bylo vhodné játra ještě rozdělit a intenzity v jednotlivých částech normalizovat nebo pro každou část použít upravené parametry jednotlivých metod.

Pokud pro segmentaci cévního řečiště použijeme více sérií snímků, dostáváme výrazně větší množství informace o cévních stromech. Pro nalezené cévy

získáváme vyšší míru důvěry ve výsledek segmentace, pakliže se objevují voxely identifikované jako cévy v obou zdrojových sériích a dostáváme i rozšířený cévní strom než v případě použití jednoho snímku. Nevýhodou použití více vstupních sérií snímků je vyšší časová náročnost provedení a to násobně, a také větší citlivost na parametry jednotlivých metod. Zde můžeme zvolit dva přístupy: buď volíme parametry obecné, tedy pro obě série shodné, čímž klademe důraz především na to, abychom s velkou pravděpodobností identifikovali jisté cévy (předpokládáme že jsou obě série podobné co se velikosti cév a intenzity jednotlivých struktur týče), nebo definovat parametry pro každou sérii snímků zvlášť, což je vhodné pro analýzu rozdílu mezi sériemi nebo získání co nejrozsáhlejšího cévního stromu. Oddělené určování parametrů použijeme i tam, kde se jedná o snímky s různými vlastnostmi (intenzity, odlišné rozlišení, různá modalita, atp.).

Především segmentační metody by bylo možné doplnit nebo rozšířit metodou machine learningu například pomocí konvolučních sítí, tyto metody ovšem vyžadují existenci segmentovaných cévních řečišť s velkou přesností na vstupu tak, aby bylo možné natrénovat machine learning algoritmy, jakými jsou například neuronové sítě. Vylepšení výsledků segmentace je možné také již v průběhu pořizování jednotlivých snímků, kdy může být s ohledem na další zpracování vhodně volen rozsah intenzit, rozlišení apod.

SEZNAM OBRÁZKŮ

2.1	EMI mark I	3
2.2	Vliv počtu projekcí na výsledný obraz	5
2.3	Výpočet absorpce	5
2.4	Princip výpočtu zeslabení voxelů	6
2.5	Radonova transformace	7
2.6	Nastavení rozsahu HU	8
3.1	DICOM	10
4.1	ITK a SimpleITK	11
5.1	Histogram equalization	12
5.2	CLAHE	13
5.3	CLAHE ukázka	13
5.4	Konvoluce	14
5.5	Metoda rotující masky	15
5.6	Vyhlazování šumu	17
6.1	Non-maximum supression	20
6.2	Non maximum supression ukázka	20
6.3	Prahování	23
6.4	Cannyho hranový detektor	25
6.5	Konvoluce s různými maskami	26
6.6	Watershed segmentation	27
6.7	Houghova transformace	28
6.8	Příklad Gaborova filtru	32
6.9	K-means	32
7.1	Rigid-body transformace	35
7.2	Non-Rigid-body transformace	36
7.3	Afinní transformace	36
7.4	Obecné schéma registrace obrazových dat	38
7.5	Výsledek křížové korelace	39
7.6	B-Spline	43
7.7	Bilineární interpolace	45
7.8	Bikubická interpolace	46
8.1	Schéma registrace	47

8.2	Registrace obrazových dat	49
8.3	Detail výsledků registrace obrazových dat	50
8.4	Ukázka segmentace v programu LISA	51
8.5	Schéma segmentace	52
8.6	Segmentace cévního stromu	54
8.7	Segmentace cévního stromu pro jednotlivé série registrovaných CT snímků	55
8.8	Segmentace cévního stromu registrovaných obrazových snímků (Frangiho filtr)	56
8.9	Segmentace cévního stromu registrovaných obrazových snímků (Region Grow)	57

SEZNAM TABULEK

2.1	Orientační hodnoty HU	8
2.2	Rozdíl mezi CT a MRI	9
5.1	Časová náročnost pro jednotlivé metody	18
6.1	Souvislost velikosti vlastního čísla s tvarem zkoumané struktury .	31
7.1	Porovnání korelace s a bez použití FFT	40
8.1	Porovnání registračních metod <i>Pozn.: Počet iterací metody B-Spline byl omezen na 20 z důvodu dlouhého času běhu algoritmu. Zbylé dvě metody byly zastaveny podmínkou minimální kovergence - ustálily se dříve, než dosáhly maximálního počtu iterací.</i>	48
8.2	Porovnání segmentovaných voxelů identifikovaných jako cévy . .	58
8.3	Porovnání segmentovaných voxelů identifikovaných jako cévy . .	59

SEZNAM POUŽITÉ LITERATURY

- [1] Jan Hugo: *Velký lékařský slovník*. Maxdorf, Praha, 2015. ISBN: 978-80-7345-456-2
- [2] Jozef ROSINA, Leoš NAVRÁTIL: *Medicínská biofyzika*. Grada, Praha, 2005. ISBN: ISBN 80-247-1152-4
- [3] Vojtěch MORNSTEIN, Ivo HRAZDIRA: *Lékařská biofyzika a přístrojová technika*. Neptun, Brno, 2001. ISBN: 80-902896-1-4.
- [4] Renáta Chylíková: *Výpočetní tomografie s vysokým rozlišením – jeho úloha a postavení v radiodiagnostice - Bakalářská práce*. Zdravotně sociální fakulta, Jihočeská univerzita v Českých Budějovicích, 2011.
- [5] Tomáš Paleček: *MRI Srdce*. II. interní klinika kardiologie a angiologie, 1. LF UK a VFN, Praha ICRC, Brno
- [6] J. B. Antoine Maintz and Max A. Viergever: *An Overview of Medical Image Registration Methods*. Imaging Science Department, Imaging Center Utrecht
- [7] Guoli Song, Jianda Han, Yiwen Zhao, Zheng Wang and Huibin Du *A Review on Medical Image Registration as an Optimization Problem*
- [8] Tavares J.M. *Analysis of biomedical images based on automated methods of image registration*; 10th International Symposium on Visual Computing; Las Vegas, USA. 2014. pp. 21–30.
- [9] Uchida S. *Image processing and recognition for biological images.*; Dev. Growth Differ. 2013;55(4):523–549.
- [10] Hill D.L., Batchelor P.G., Holden M., Hawkes D.J. *Medical image registration.* ; Phys. Med. Biol. 2001;46(3):R1–R45.
- [11] ITK Documentation
- [12] Simple ITK Documentation
- [13] Martin Sedlář *Magnetická rezonance*; 2011, Lékařská fakulta Masarykovy univezity

-
- [14] Josien P. W. Pluim, J. B. Antoine Maintz and Max A. Viergever *Mutual information based registration of medical images: a survey*. IEEE TRANSACTIONS ON MEDICAL IMAGING, VOL. XX, NO. Y, MONTH 2003
- [15] Witold Kosiński, Paweł Michalak, Piotr Gut *Robust Image Registration Based on Mutual Information Measure*. Faculty of Computer Science, Polish-Japanese Institute of Information Technology, Warszawa, Poland; Institute of Mechanics and Applied Computer Science, Kazimierz Wielki University, Bydgoszcz, Poland.
- [16] F. Maes, A. Collignon, D. Vandermeulen, G. Marchal and P. Suetens *Multimodality Image Registration by Maximization of Mutual Information*. IEEE Transactions on Medical Imaging, Vol. 16, No. 2, 1997, pp. 187-198.
- [17] <https://github.com/mjirik/lisa/>
- [18] Yuri Y. Boykov, Marie-Pierre Jolly *Interactive Graph Cuts for Optimal Boundary and Region Segmentation of Objects in N-D Images*. Siemens Corporate Research 755 College Road East, Princeton, NJ 08540, USA 2001
- [19] Yuri Boykov, Olga Veksler, Ramin Zabih *Fast Approximate Energy Minimization via Graph Cuts* IEEE transactions on PAMI, vol. 20, no. 12, p. 1222-1239. 2001
- [20] Zhayida Simayijiang, Stefanie Grimm *Segmentation with Graph Cuts*
- [21] Miroslav JIŘÍK, Tomáš RYBA *INTERAKTIVNÍ SEGMENTACE POMOCÍ METODY GRAPH-CUT V PROSTŘEDÍ MATLAB*, ZČU Fakulta Aplikovaných věd
- [22] Pavel ŠPATENKA *POUŽITÍ SEGMENTAČNÍ METODY GRAPH-CUT V BALÍKU ITK*
- [23] Ing. Marek Hrúz Ph.D. *Adaptive Histogram Equalization, Histogram processing and Convolution*, ZČU Fakulta Aplikovaných Věd, Katedra Kybernetiky
- [24] TOMÁŠ VINTR *GAUSSOVSKÉ FILTRY S ROTUJÍCÍM JÁDREM*. Diplomová práce, VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, FAKULTA STROJNÍHO INŽENÝRSTVÍ, USTAV MATEMATIKY
- [25] Ahmad EL ALLAOUI, M'barek NASRI *MEDICAL IMAGE SEGMENTATION BY MARKERCONTROLLED WATERSHED AND MATHEMATICAL MORPHOLOGY*. LABO MATSI, ESTO, B.P 473, University Mohammed I Oujda, MOROCCO

-
- [26] Lei Zhang, Mark Fisher, Wenjia Wang *Retinal Vessel Segmentation Using Gabor Filter and Textons*. School of Computing Sciences, University of East Anglia, UK
- [27] João V. B. Soares, Jorge J. G. Leandro, Roberto M. Cesar-Jr., Herbert F. Jelinek, and Michael J. Cree *Retinal Vessel Segmentation Using the 2-D Morlet Wavelet and Supervised Classification*, Article in IEEE Transactions on Medical Imaging · October 2006
- [28] Adebayo Olowoyeye, Mihran Tuceryan, Shiao-fen Fang *Medical Volume Segmentation using Bank of Gabor Filters*, Conference Paper · January 2009
- [29] Sonka, M., Hlavac, V., Boyle, R. *Image Processing, Analysis, and Machine Vision Second Edition*. Thomson-Engineering.
- [30] Barbara Zitová, Jan Flusser *Image registration methods: A survey. Image and Vision Computing*. 2003
- [31] Oliveira, D. A., Feitosa, R. Q., Correia, M. M. *Segmentation of liver, its vessels and lesions from CT images for surgical planning.*, BioMedical Engineering OnLine, 10(1),
- [32] Ing. Michal Španěl, Ing. Vítězslav Beran: *Obrazové segmentační techniky*. FAKULTA INFORMAČNÍCH TECHNOLOGIÍ, VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, 2005
- [33] J. B. Antoine Maintz, Max A. Viergever: *An Overview of Medical Image Registration Methods*. Imaging Science Department, Imaging Center Utrecht
- [34] Y. Raghavender Rao, Nikhil Prathapani, E. Nagabhooshanam *APPLICATION OF NORMALIZED CROSS CORRELATION TO IMAGE REGISTRATION*. International Journal of Research in Engineering and Technology, eISSN: 2319-1163 | pISSN: 2321-7308.
- [35] Bogdan J. Matuszewski , Lik-Kwan Shark , Martin R. Varley *Rigid-body transformation*. Department of Engineering and Product Design, University of Central Lancashire Preston, PR1 2HE, United Kingdom